



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF BIOMEDICAL ENGINEERING

KLASIFIKACE SPÁNKOVÝCH FÁZI ZA POUŽITÍ POLYSOMNOGRAFICKÝCH DAT

CLASSIFICATION OF SLEEP PHASES USING POLYSOMNOGRAPHIC DATA

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. MARTIN KRÁLÍK

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. MARINA RONZHINA

BRNO 2015



**VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ**

**Fakulta elektrotechniky
a komunikačních technologií**

Ústav biomedicínského inženýrství

Diplomová práce

magisterský navazující studijní obor
Biomedicínské a ekologické inženýrství

Student: Bc. Martin Králík

ID: 133972

Ročník: 2

Akademický rok: 2014/2015

NÁZEV TÉMATU:

Klasifikace spánkových fází za použití polysomnografických dat

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s metodami pro klasifikaci spánkových fází na základě polysomnografických záznamů pacientů. 2) Proveďte výpočet vybraných parametrů z alespoň dvou druhů signálů snímaných v průběhu různých spánkových fází. Použijte signály dostupné v databázi na ÚBMI. Pomocí statistické analýzy vyberte parametry vhodné pro následnou automatickou klasifikaci spánkových fází. 3) Na základě literární rešerše a výsledků analýzy jednotlivých parametrů EEG navrhnete postup pro následnou klasifikaci. 4) Realizujte navržený klasifikační postup a otestujte ho na dostupných záznamech. 5) Proveďte hodnocení úspěšnosti klasifikace a porovnejte dosažené výsledky s dostupnými údaji z literatury. Dosažené výsledky diskutujte.

DOPORUČENÁ LITERATURA:

[1] SÖRNMO, Leif a Pablo LAGUNA. Bioelectrical signal processing in cardiac and neurological applications. Academic Press, 2005, 688 s. ISBN 978-0-12-437552-9.

[2] MOSER, Doris et al. Sleep classification according to AASM and Rechtschaffen & Kales: Effects on Sleep Scoring Parameters. Sleep. 2009, č. 32, s. 139-149. ISSN 1550-9109.

Termín zadání: 9.2.2015

Termín odevzdání: 22.5.2015

Vedoucí práce: Ing. Marina Ronzhina

Konzultanti diplomové práce:

prof. Ing. Ivo Provazník, Ph.D.

Předseda oborové rady

UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

Abstrakt

Cílem této diplomové práce je klasifikace spánkových fází za použití polysomnografických dat. Součástí práce je rešerše na dané téma a statistická analýza parametrů vypočtených ze skutečných signálů EEG, EOG a EMG, která hodnotí vhodnost jejich použití pro klasifikaci spánkových fází. Praktická část je zaměřena na automatickou klasifikaci spánkových fází za použití umělých neuronových sítí. Všechny výsledky jsou v práci prezentovány a diskutovány.

Klíčová slova

Spánkové fáze, polysomnografie, klasifikace, umělé neuronové sítě

Abstract

Aim of this thesis is the classification of polysomnographic data. The first part of the thesis is a review of mentioned topic and also the statistical analysis of classification features calculated from real EEG, EOG and EMG for evaluating of the features suitability for sleep stages scoring. The second part is focused on the automatic classification of the data using artificial neural networks. All the results are presented and discussed.

Key words

Sleep stages, polysomnography, classification, artificial neural networks

Bibliografická citace

KRÁLÍK, M. *Klasifikace spánkových fází za použití polysomnografických dat*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2015. 72 s. Vedoucí diplomové práce Ing. Marina Ronzhina.

Prohlášení

Prohlašuji, že svou diplomovou práci na téma Klasifikace spánkových fází za použití polysomnografických dat jsem vypracoval samostatně pod vedením vedoucího semestrálního projektu a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedeného diplomové práce dále prohlašuji, že v souvislosti s vytvořením tohoto projektu jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009Sb.

V Brně dne 20.5.2015

Podpis autora: _____

Poděkování

Na tomto místě bych chtěl poděkovat vedoucí diplomové práce, Ing. Marině Ronzhině, za odbornou pomoc a cenné rady, poskytnuté při zpracování této práce.

V Brně dne 20.5.2015

Podpis autora: _____

Obsah

1. Úvod	- 2 -
2. Polysomnografie.....	- 3 -
2.1. Elektroencefalografie	- 3 -
2.2. Elektromyografie.....	- 5 -
2.3. Elektrookulografie	- 6 -
2.4. Standard AASM	- 7 -
3. Klasifikace PSG dat.....	- 11 -
3.1. Hodnocení v časové oblasti	- 11 -
3.2. Hodnocení ve frekvenční oblasti	- 12 -
3.3. Časově-frekvenční analýza.....	- 13 -
3.4. Klasifikační metody.....	- 15 -
4. Práce s PSG daty	- 18 -
4.1. Použitá data	- 18 -
4.2. Práce se signálem v časové oblasti	- 21 -
4.3. Práce se signálem ve frekvenční oblasti	- 28 -
4.4. Práce se signálem v časově-frekvenční oblasti.....	- 30 -
5. Klasifikace spánkových fází.....	- 33 -
5.1. Vytvoření klasifikačních příznaků a neuronové sítě	- 33 -
5.2. Data od jednoho pacienta	- 36 -
5.3. Data od dvou pacientů	- 42 -
5.4. Data od třech pacientů	- 48 -
5.5. Data od čtyř pacientů.....	- 55 -
5.6. Shrnutí a porovnání výsledků	- 61 -
6. Závěr.....	- 63 -
Seznam použitých zkratk	- 64 -
Seznam obrázků	- 65 -
Seznam tabulek	- 68 -
Seznam použité literatury	- 69 -
Přílohy.....	- 72 -

1. Úvod

Spánek je, zjednodušeně řečeno, požadovaný stav bezvědomí. Úmyslně uléháme každý večer, aby se naše tělo zregenerovalo a odpočalo. Na moderního člověka však působí celá řada vlivů, které mají na spánek negativní vliv, jako jsou stres, špatné stravování, léky, nezdravé prostředí a další řada problémů, které nás denně doprovází. Tyto vlivy pak mají za následek krátký, nekvalitní či dokonce téměř žádný spánek. Vznikají tak spánkové poruchy, jako jsou nespavost, narkolepsie či spánková apnoe. Tyto poruchy se pak promítají do všedního života, například v podobě depresí a dalších poruch. Není tak divu, že za poslední století vznikla řada odvětví, která se spánkovou problematikou zabývají. [5],[15],[16]

Počátky výzkumu spánku se datují do 30. let 20. století a jsou spojeny s objevem elektroencefalogramu. V roce 1937 bylo díky němu zjištěno, že spánek není v průběhu noci homogenní a začaly se objevovat první rozdělení na spánkové fáze. Tomuto dělení velmi přispělo roku 1953 objevení zvláštní fáze spánku, při které se zdají sny a dochází k rychlému pohybu očí – REM fáze. Bylo však potřeba určit nějaký standard pro skórování spánku a tak v roce 1968 Rechtschaffen a Kales (R&K) vydávají manuál, ve kterém dělí spánek na fázi bdění (W), 4 fáze non-REM spánku (S1-4) a REM fázi. Tento manuál se stal standardem na dalších 40 let, během kterých došlo k řadě objevů v oblasti zkoumání spánku. To mělo za následek vyvinutí nového manuálu pro skórování spánkových fází v letech 2004 až 2006, Americkou akademií spánkové medicíny (AASM). Ta ponechala z původního manuálu fáze W a REM (někdy uváděna také jako R), 4 non-REM fáze byly redukovány na tři (N1-3) spojením S3 a S4 fází. Tento manuál obsahuje obsáhlý soubor rozhodovacích pravidel a doporučení pro klasifikaci spánkových fází a je považován za standard dodnes. [15],[16]

Následující diplomová práce je ve své první polovině pojata jako literární rešerše, zabývající se informacemi o polysomnografii (PSG) a standardu AASM. Zabývá se také klasifikačními metodami, používanými v již existujících postupech pro automatickou klasifikaci spánkových fází. Druhá část práce je ryze praktická, v jednotlivých podkapitolách je věnován prostor reálným PSG záznamům od pacientů, práci s nimi a následně pak automatické klasifikaci. Pro samotnou klasifikaci jsou nastaveny různé podmínky, jako například data od měněního se počtu pacientů, či počet klasifikovaných spánkových fází, tak, aby co nejlépe znázornily úspěšnost použité klasifikační metody.

2. Polysomnografie


Jak již bylo zmíněno, studium spánkových fází má své začátky spojené s objevením elektroencefalografu. V následujících letech bylo ovšem zjištěno, že se v průběhu spánku mění pochody v celém těle a že o spánkových fázích mohou vypovídat i jiné signály. Zjistilo se například, že s hlubším spánkem klesá svalový tonus, během REM fáze dochází k rychlému pohybu očí a kolísá srdeční rytmus, což mělo za následek, že se začaly snímat současně s elektroencefalogramem i další signály. Vznikla tak polysomnografie (PSG), měření více parametrů během spánku. Nejčastěji měřenými signály jsou: elektroencefalogram (EEG), elektrookulogram (EOG) a elektromyogram (EMG). Není ovšem výjimkou, že se současně s nimi snímají i další signály, jako elektrokardiogram (EKG), krevní tlak, respirační či dokonce renální funkce. V následujících podkapitolách bude věnován čas těm nejčastěji používaným, tedy EEG, EMG a EOG. [17]

2.1. Elektroencefalografie

EEG patří spolu s EKG k nejznámějším a patrně také nejčastěji snímaným biosignálům. Elektroencefalografie je technika, která umožňuje zaznamenávat elektrickou aktivitu mozku. Mimo diagnostiku spánkových poruch se rovněž užívá k diagnostice epilepsie, mozkových nádorů a dalších. Nutné je podotknout, že snímáme rozložení elektrické činnosti v různých částech mozku, jedná se tedy o superpozici více jednodušších signálů.[8]

Pro měření EEG jsou používány Ag/AgCl nebo zlaté elektrody o velikosti zhruba 10mm, jež jsou umístěny na kůži hlavy. Pro zlepšení přenosu signálu je vhodné použití brusných past a vodivých gelů. Standardně se pro rozmístění elektrod užívá mezinárodní systém „10/20“, signál se měří proti referenční elektrodě, ta ovšem není přesně daná. Většinou se měří proti elektrodám na ušních lalůčkách, případně proti elektrodě Fpz. Výjimkou ovšem není měření proti kterékoliv elektrodě (například svod Cz-Oz). Obecně se za užitečné pásmo uvažují frekvence 0.5 – 110 Hz, vzorkovací kmitočet obvykle 500Hz (minimálně 200Hz). [8],[17]

Výše zmíněné rozmístění elektrod „10/20“ doporučuje pro spánkové studie i AASM. Doporučené a alternativní svody ukazuje Obrázek 2.1, AASM doporučuje užití svodů F₄-M₁, C₄-M₁ a O₂-M₁, alternativně lze ovšem použít i svody podle části B. V této práci je v praktické části pracováno se svody Fz-Cz, C₃-M₂ a Cz-Oz. Frekvenční pásmo je podle AASM doporučováno 0.3 až 35Hz, někdy se v literatuře ovšem doporučují horní hranici vyšší, například 0.3 až 70Hz. [17]




Obrázek 2.1 Doporučené (A) a alternativní (B) svody EEG, dle doporučení AASM [17]

Při zpracování EEG signálu pro klasifikaci spánkových fází nás zajímá především spektrální složení signálu. To totiž pro tyto potřeby mnohem lépe vystihuje aktivitu mozku, než časová oblast signálu. Frekvence EEG se dělí na několik pásem (rytmů), uvedených v Tabulka 2.1. Přítomnost jednotlivých rytmů závisí na stupni pozornosti a bdělosti, což je rovněž zahrnuto v tabulce. Horní frekvence beta pásma se v různé literatuře liší, obvykle se udávají hodnoty 30Hz, případně 35Hz. Obecně lze ovšem říci, že se jedná o složky EEG signálu o frekvenci vyšší než 13Hz. [8],[15],[17]

Tabulka 2.1 Frekvenční rozdělení vln v EEG

Označení vlny	Frekvenční pásmo [Hz]	Poznámka
Delta vlny - δ	0 – 4	Indikují spánek
Theta vlny - θ	4 – 8	Indikují spánek
Alfa vlny - α	8 – 13	Bdělost, zavřené oči
Beta vlny - β	>13	Bdělost, vyšší aktivita

Při hodnocení spánkových fází hrají roli nejen výše uvedená frekvenční pásma, ale rovněž i kratší události, tzv. grafoelementy. Z nich především spánková vřetena a K-komplexy. Ukázkou obou představuje Obrázek 2.2. Spánková vřetena jsou krátké úseky signálu s frekvencí 11 – 16 Hz, převážně 14Hz. K-komplex je EEG jev s nejvyšší amplitudou, jedná se o ostrou negativní vlnu následovanou pomalejší kladnou vlnou. V obou případech se jedná o jevy s trváním delším než 0.5s a doprovází nejčastěji druhou fázi non-REM spánku. [17]




Obrázek 2.2 Ukázka spánkových vřeten (nahore) a K-komplexu (dole) [17]

2.2. Elektromyografie

Ačkoliv je EEG bezesporu nejdůležitějším signálem pro klasifikaci spánkových fází, další měřené parametry výrazně přispívají k přesnosti klasifikace. Jedním z takových signálů je snímání elektrické aktivity svalových buněk – elektromyografie (EMG). Podobně jako EEG se snímá pomocí elektrod z povrchu těla (invazivní metoda se u PSG nevyužívá), ty zachycují signál generovaný svalovými vlákny. Tento signál vzniká aktivací svalových buněk, trvá obvykle 2 až 15ms s amplitudou 20 až 2000 μ V. Dominantní frekvence se nachází v rozsahu 20 až 250Hz. Použité elektrody jsou podobné jako například pro EKG, obvykle ale mají menší plochu pro vyšší přesnost místa snímání. [8]

Při měření PSG se obvykle používá měření svalového tonu pomocí submentální EMG (EMGsub), kdy jsou elektrody umístěny zhruba 2cm pod spodním okrajem dolní čelisti a asi 2cm nalevo a napravo od pomyslné střední čáry, jak popisuje Obrázek 2.3. Pro lepší vodivost je rovněž doporučeno užití pasty, pro lepší stabilitu elektrod během spánku mohou být elektrody připevněny páskou. Vzorkovací frekvence se doporučuje alespoň 500Hz s užitečným pásmem 10 až 100Hz. U EMGsub jde především o měření svalového tonu, který se v průběhu noci snižuje až k minimu v průběhu REM fáze. [17]




Obrázek 2.3 Umístění elektrod pro měření EMGsub [3]

2.3. Elektrookulografie

Posledním typem signálu, kterým se tato diplomová práce blíže zabývá je EOG. Spolu s EEG a EMG tvoří nejčastěji používanou trojici signálů, používaných ke klasifikaci spánkových fází. Oko člověka můžeme považovat za dipól s kladnou rohovkou proti záporné sítnici. EOG se používá k registraci elektrických klidových očních potenciálů mezi předním a zadním pólem oka. Umístění elektrod se pak liší, obvykle jsou umístěny nasálně a temporálně v těsné blízkosti oka, referenční elektroda je obvykle na ušním lalůčku. Pro měření se používají Ag/AgCl elektrody o malých rozměrech, signál pak nabývá hodnoty stovek mikrovolt až milivoltů. Mimo PSG se EOG využívá například pro diagnostiku degenerace sítnice či toxických látek ovlivňujících vidění. [8]

Při měření PSG se technické parametry EOG neliší od běžného měření. Data, jež jsou použita v této semestrální práci, obsahují EOG signály měřené s rozmístěním elektrod podle Obrázek 2.4. Při hodnocení jde především o detekci rychlých pohybů očí během REM fáze. Tyto pohyby se na EOG projevují jako píky o velikosti <500ms. [17]



Obrázek 2.4 Možné rozmístění elektrod při měření EOG [17]


Tři výše uvedené signály tvoří základ pro klasifikaci spánkových fází. PSG ale obvykle obsahuje mnohem širší spektrum parametrů, jejichž použití závisí na situaci a především na důvodu provádění spánkové studie. Z dalších signálů lze uvést například [17]:

- Měření respirace – možno provádět pomocí pneumotachografie, mnohem běžnější je ale použití nasálního teploměru pro odhad průtoku vzduchu, dále měření dýchacího úsilí pomocí pásů na hrudi a břichu pacienta
- Měření okysličené krve – souvisí obvykle s měřením respirace, pro měření se užívá pulsní oxymetr
- Pohyb – měření pomocí EMG, elektrody jsou umístěny na přední stranu bérce
- Srdeční činnost – snímání pomocí EKG, možno měřit i krevní tlak
- Další parametry – teplota těla, měření hladiny hormonů v krvi, spontánní erekce, chrápání, osvětlení místnosti a další.

2.4. Standard AASM


V úvodu byl stručně naznačen vývoj studia spánkových fází z historického hlediska. Pro moderní skórování spánku je nejdůležitější rok 2007, kdy byl vydán manuál AASM. Ten definuje nejen dnes běžně uznávané rozdělení spánku na pět fází, ale rovněž doporučené postupy pro měření polysomnografických dat a pro jejich klasifikaci. Jedním z takových doporučení je například vytváření hypnogramu ve 30s epochách. Celý záznam spánku se rozdělí na 30s úseky, každý z takových úseků (epoch) se poté vyhodnotí a je mu přiřazena jedna z pěti spánkových fází. Soubor hodnocení se nazývá hypnogram a obvykle nabývá číselných hodnot, přiřazených pro každou ze spánkových fází. [5]

Fáze wake (W) představuje stav bdělosti a plného uvědomění si okolí. Je typická přítomností alfa rytmu nad okcipitální oblastí při zavřených očích. Rovněž se při této fázi objevují rychlé nebo čtecí pohyby očí. Rychlé pohyby očí jsou sice typické pro REM fázi, během bdění se nicméně mohou objevit při otevřených očích, kdy subjekt zkoumá okolí. Na SubEMG naměříme proměnlivou amplitudu, zpravidla však vyšší než při dalších fázích. Pro klasifikaci fáze jako W je důležitá přítomnost alfa rytmu ve více než 50% epochy. Pokud tento rytmus rozlišit nelze, je fáze klasifikována jako W tehdy, pokud se objevuje mrkání (frekvence 0.5-2Hz) nebo čtecí pohyby očí. Ukázka fáze W je na Obrázek 2.5 a byla vytvořena z reálných PSG dat, používaných dále v práci, shora vidíme signály EEG ze svodu Cz-Oz, signál EOG z levého oka a signál subEMG. Během této konkrétní 30 sekundové epochy můžeme pozorovat pohyby očí, doprovázející bdění, rovněž vysoké frekvence v signálu EEG a vyšší hodnoty u EMG. [5]




Obrázek 2.5 Ukázka fáze W

Non-REM 1 fáze (N1) je jakýmsi přechodem mezi bděním a spánkem. Trvá obvykle 1-5 minut a představuje celkově asi 4-5% celkového spánku. Pro tuto fázi jsou typické pomalé pohyby očí, trvající déle než 0.5s. EEG signál vykazuje nízkou amplitudu s frekvencí 4-7Hz. Klasifikujeme tehdy, pokud se objeví alfa rytmus, který během epochy zeslábné a je nahrazen zmíněnou aktivitou o nízké amplitudě. Pomocná pravidla jsou: přítomnost pomalého pohybu očí, případně přítomnost ostrých V vln v EEG. Pomalé pohyby očí vidíme i na ukázce fáze N1 na Obrázek 2.6. [5]




Obrázek 2.6 Ukázka fáze N1

Non-REM 2 fáze (N2) představuje základ spánku a může tvořit 45-55% jeho trvání. Pro tuto fázi jsou, jak již bylo několikrát zmíněno, typické K-komplexy a spánková vřetena. Jejich přítomnost je také rozhodujícím faktorem pro klasifikaci fáze N2. EOG signál neukazuje obvykle žádné oční pohyby, výjimečně mohou u některých jedinců přetrvávat pomalé pohyby z předchozí fáze. EMG signál má obvykle nižší amplitudu než v předchozích fázích, může klesnout až na úroveň REM spánku. Na Obrázek 2.7 můžeme pozorovat, že během fáze N2 vymizely pomalé pohyby očí z předchozí fáze, stejně jako vyšší frekvence ze signálu EEG, snížila se úroveň signálu EMG. [2],[5]




Obrázek 2.7 Ukázka fáze N2

Non-REM 3 fáze (N3) je fází hlubokého spánku. Tomu odpovídá i signál EEG o nízké frekvenci, obvykle 0.5-2Hz a amplitudě $>75\mu V$, měřeno nad frontální oblastí. Jako N3 vyhodnotíme fázi tehdy, pokud více než 20% epochy obsahuje tyto pomalé vlny. Pro EOG a EMG signály platí stejné podmínky, jako u předchozí fáze. Během hlubokého spánku se rovněž mohou v EEG objevovat spánková vřetena. Ukázku fáze N3 vidíme na Obrázek 2.8, povšimnout si můžeme především pomalých vln na signálu EEG nad frontálním lalokem, rovněž vidíme další pokles signálu EMG, který dosahuje během této fáze velmi nízkých hodnot, podobných fází REM. [5]



Obrázek 2.8 Ukázka fáze N3

REM fáze (R), je fází spánku, během které se nám zdají sny a obvykle tvoří 20-25% spánku. EEG signál má nízkou amplitudu a je tvořen různými frekvencemi, objevují se pilovité vlny o frekvenci 2-6Hz. Úroveň subEMG dosahuje během této fáze nejnižších hodnot z celého záznamu. Typické jsou rychlé, nepravidelné pohyby očí, tvořící ostré píky na EOG signálu. Tyto tři jevy – rychlé pohyby očí, nízký svalový tonus a smíšené frekvence EEG o nízké amplitudě – jsou také hlavními podmínkami pro klasifikaci R fáze. Všechny tyto jevy také pozorujeme na ukázce na Obrázek 2.9, rychlé pohyby očí pozorujeme především mezi 15. a 20. sekundou záznamu. [2],[5]



Obrázek 2.9 Ukázka fáze REM

3. Klasifikace PSG dat

Přestože žijeme v době, kdy existuje řada počítačových algoritmů pro klasifikaci spánkových dat, používá se v praxi stále manuální vyhodnocení lidským expertem. Takový expert si na monitoru zobrazuje všechny potřebné signály v 30s intervalech a určuje, o kterou spánkovou fázi se jedná. Takové hodnocení je, vzhledem k množství dat, složitý a časově náročný proces. Klasifikace osmihodinového spánku zabere 2-4 hodiny (pokud se neprovádí současně při spánku pacienta) a navíc je zatíženo subjektivním rozhodováním a tudíž chybou. Shoda dvou různých expertů se udává pouze $83 \pm 3\%$, což lze považovat za nízkou hodnotu [15]. Z toho důvodu je v dnešní době snaha nahrazovat lidské experty sofistikovanými klasifikačními systémy, umožňujícími mnohem rychleji a s dostatečnou přesností vyhodnotit spánkové záznamy.

3.1. Hodnocení v časové oblasti

Nejjednodušším způsobem jak klasifikovat naměřený signál je pracovat přímo s naměřenými hodnotami, mluvíme o práci v časové oblasti. Zde se nabízí množství způsobů, jak se signálem pracovat, jedním z nich je statistická analýza. K této analýze můžeme použít střední hodnotu, směrodatnou odchylku, rozptyl či kvadratický průměr (Root Mean Square, RMS), dále medián, koeficient šikmosti nebo koeficient špičatosti. Pro EEG signály se dále hodí použít Hjorthovy parametry, pro které se používají hodnoty rozptylu, první a druhé derivace, tyto parametry ovšem v této práci použity nejsou. [9]

V této části práce byly pro statistickou analýzu vypočteny tři parametry ze signálů EEG a EOG. Těmito parametry jsou [13]:

- Střední hodnota:

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i, \quad (3.1)$$

kde x_i jsou jednotlivé hodnoty signálu a N je velikost délka signálu

- Rozptyl – určuje míru rozptýlení hodnot ve statistickém souboru:

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2, \quad (3.2)$$

kde x_i jsou jednotlivé hodnoty souboru, N je velikost souboru hodnot (délka signálu) a \bar{x} je střední hodnota

- Směrodatná odchylka – odmocnina rozptylu

V časové oblasti však statistický rozbor není jedinou možností, jak získat užitečné informace. Při skórování spánkových fází za použití EEG nás především zajímá spektrální složení signálu. Pro přesnou detekci fáze N2 je ale, jak již bylo zmíněno výše, vhodné detekovat K-komplexy. Pro takovou detekci lze použít řadu metod, nejčastěji se používají korelační detektory.

U signálů EOG a EMG nás bude zajímat především amplituda signálů. V případě EOG lze očekávat nepravidelné pohyby očí během bdělosti, s upadáním do hlubšího spánku tyto pohyby pravděpodobně vymizí. Během REM spánku se znovu objeví pohyby očí, v porovnání s fází bdění však budou mít kratší trvání. U EMG signálu budeme zkoumat úroveň svalového tonu. Ten bude nejvyšší ve fázi bdění a postupně bude klesat, až na nejnižší hodnotu během REM spánku. Pro zkoumání obou signálů tak lze použít okno klouzající po záznamu a vyhodnocující velikost amplitudy.

3.2. Hodnocení ve frekvenční oblasti

Jak bylo zmíněno v předchozí kapitole, u EEG signálu je důležité především zastoupení jednotlivých frekvencí. Pravděpodobně nejznámějším způsobem, kterým lze získat informace o spektru signálu je Fourierova transformace (FT). Pracuje s ideou, že každý signál lze rozložit na určitý počet sinusových signálů. Transformací tak získáme informaci o obsahu těchto harmonických složek v signálu. Spektrum spojitého signálu je vyjádřeno vztahem [6]:

$$F(\omega) = F\{f(t)\} = \int_{-\infty}^{\infty} f(t)e^{-j\omega t} dt, \quad (3.3)$$


kde $F(\omega)$ vyjadřuje spektrum signálu, $F\{f(t)\}$ je FT funkce $f(t)$ a ω značí kmitočet. Tento vzorec je použitelný pro spojitě signály, v našem případě ale pracujeme s diskrétními signály, proto je nutné použít modifikaci vzorce (3.2), známou jako diskrétní Fourierova transformace (DFT), která N vzorkům v originální oblasti přiřazuje stejně dlouhou posloupnost ve frekvenční oblasti. Tato DFT je vyjádřena [6]:

$$DFT\{f_n\} = \left\{ F_k = \sum_{n=0}^{N-1} f_n e^{-jk\Omega nT} \right\}, \quad (3.4)$$

kde T vyjadřuje periodu vzorkování, N je počet vzorků, Ω je N -tina vzorkovacího kmitočtu a F jsou spektrální koeficienty. Existuje řada modifikací tohoto algoritmu, jež umožňují rychle a efektivně vypočítat DFT a jsou nazývány rychlá Fourierova transformace (FFT). Ve všech zmiňovaných případech nám však FT podává pouze informace o frekvenčních vlastnostech signálu, nikoliv o jejich vývoji v čase. [6]

EEG je stochastický signál a tak je pro popis jeho spektrálních vlastností vhodné použít výpočtu výkonového spektra a výkonové spektrální hustoty (PSD – Power Spectral Density).

Nutno také podotknout, že spánkové studie jsou většinou hodnoceny ve 30s epochách. Protože lze použité 30s epochy signálu považovat za dostatečně dlouhé, není problém v použití neparametrických metod, konkrétně odhad periodogramu Welchovou metodou. Dlouhý úsek signálu je rozdělen na více kratších segmentů, které se pak průměrují. Ukázku PSD vytvořené z EEG fáze vidíme na Obrázek 3.1, včetně vyznačení jednotlivých frekvenčních pásem. [6]



Obrázek 3.1 Ukázka PSD s jedné epochy PSD vyznačením frekvenčních pásem

Z vypočtené PSD lze pak určit relativní zastoupení jednotlivých frekvenčních pásem v signálu EEG, například u zastoupení delta pásma bychom sečetli všechny hodnoty PSD odpovídající delta pásmu a následně je vydělili sumou všech hodnot PSD. Takový vypočtený parametr může posloužit jako klasifikační příznak při skórování spánkových fází.

3.3. Časově-frekvenční analýza

Použití DFT na signál EEG nám sice přinese velmi ceněné informace o spektru signálu, bohužel ale nezískáme informace o jeho změnách v čase. Teoreticky integrální FT pracuje se signálem nekonečné délky, a tak nelze jakékoliv informace o časovém vývoji získat. V praktickém použití u diskrétních signálů však pracujeme s omezeným úsekem signálu, a tak se nabízí možnost, provést výpočet několika spekter z kratších úseků signálů a sledovat tak vývoj spektra v rámci epochy. Takový koncept krátkodobých spekter nazýváme časově-spektrální analýza. [6]

Pokud provádíme u signálu určité délky FT v klouzavém (a zpravidla mnohem kratším) okně, získáme soubor spekter, nazývaný spektrogram. Ten může být zobrazen jako dvojrozměrný obraz, mající na x-ové ose časovou osu a na ose y frekvenci. Pomocí barevné


nebo šedotónové stupnice pak můžeme vyjádřit zastoupení dané frekvence v daném čase v jednotkách, které se odvíjí od použité metody. Příklad spektrogramu je na Obrázek 4.15 v kapitole 4. Při použití krátkodobé Fourierovy transformace (STFT) musíme rovněž uvažovat délku použitého okna. Na ní závisí dosažené frekvenční a časové rozlišení. Pokud například zvolíme kratší okno, získáme lepší informace o časovém vývoji na úkor informací o nízkých frekvencích. Proto je vždy nutné volit kompromis na základě analyzovaného signálu. Zlepšení časového rozlišení může rovněž poskytnout překrývající se okno. [6]

Výslední spektrogram může posloužit pro automatickou i manuální klasifikaci spánkových dat. Při manuální klasifikaci nám spektrogram poskytuje informace o vývoji spektra signálu v čase ve formě snadno pochopitelné a přehledné. Při automatické klasifikaci pak lze využít hodnoty spektrogramu obdobně, jako při práci s PSD, neboť máme vypočteno větší množství dílčích spekter, můžeme tak získat přehled nejen o relativním zastoupení jednotlivých frekvenčních pásem EEG, ale i o jejich vývoji v čase.

Moderní alternativou k použití STFT je vlnková transformace. Jak název napovídá, k rozkladu signálu dochází pomocí básových funkcí, zvaných mateřské vlnky. Vlnková transformace není jednou metodou, ale souhrnným názvem pro metody, využívající širokou škálu různých mateřských vlnek. Hlavním cílem transformace je získání optimálního časového a frekvenčního rozlišení. Toho je dosaženo dilatací (změnou měřítka) daného typu mateřské vlnky, díky tomu získáme vyšší časové rozlišení u vysokých frekvencí a vyššího frekvenčního rozlišení u nízkých frekvencí. Spojitou vlnkovou transformaci vyjádříme jako [6]:

$$S_{CWT}(a, \tau) = \int_{-\infty}^{\infty} s(t) \frac{1}{\sqrt{a}} \Psi\left(\frac{t}{a} - \tau\right) dt, \quad (3.3)$$

kde $s(t)$ je vstupní signál, a vyjadřuje měřítko mateřské vlnky Ψ a τ její posun podél časové osy. Ukázku rozkladu signálu pomocí vlnkové transformace vidíme na Obrázek 3.2. Jedná se o diskrétní vlnkovou transformaci akustického signálu, zaznamenávajícího česká slova „devadesát čtyři“.




Obrázek 3.2 Diskrétní vlnková transformace akustického signálu (převzato a upraveno [6])

3.4. Klasifikační metody

Výše uvedenými metodami jsme schopni pro každou epochu PSG záznamu získat až desítky parametrů, které slouží jako klasifikační příznaky pro následné skórování spánkových fází. Nejjednodušší možností jak taková data klasifikovat je předložit je lidskému expertovi, který pak na základě nejrůznějších rozhodovacích pravidel může vyhodnotit, ke které spánkové fázi přiřadí danou skupinu parametrů. Toto řešení je však jednak časově náročné a také, jak již bylo zmíněno, zatíženo velkou subjektivní chybou. Proto je již delší dobou snaha o vytvoření jakési formy umělé inteligence, která by pomohla tyto problémy řešit a napodobila by tak intelektuální schopnosti člověka. [10]

Snaha nahradit lidského experta počítačovým systémem vedla k vývoji expertních systémů (ES), někdy také nazývaných znalostní systémy nebo též znalostní expertní systémy. Představa je taková, že se systému na vstupu předloží fakta (v našem případě klasifikační příznaky) a výstupem systému je expertíza. Samotný ES je pak tvořený dvěma částmi – znalostní bází, obsahující znalosti a interferenčním mechanismem, který tyto znalosti zpracovává. Tento interferenční systém pak využívá pravidel typu KDYŽ...POTOM...JINAK pro klasifikaci, rozhodování či plánování. Základní koncept ES můžeme vidět na Obrázek 3.3. [9],[10]




Obrázek 3.3 Koncept expertního systému [skripta AUIN]

. ES použitý pro klasifikaci spánkových fází by mohl přímo využívat směrnici AASM. Systém by tak například pro klasifikaci fáze W mohl využívat pravidel: POKUD je přítomen alfa rytmus více než v 50% epochy A NEBO jsou detekovány pohyby očí odpovídající čtení NEBO jsou detekovány frekvence 0,5-2Hz odpovídající mrkání, PAK se jedná o fázi W. [4]

Další z možností, jak klasifikovat PSG data je využití shlukové analýzy. Ta funguje následujícím způsobem – nejprve je předložena matice vstupních dat, v našem případě klasifikačních příznaků získaných z PSG. Vstupní hodnoty, atributy, můžou být dále standardizována do bezrozměrné veličiny. Následně je vypočtena nová matice podobností (vzdáleností) a na z ní jsou následně vytvářeny shluky. Snaha je taková, aby byly vytvořeny shluky podobných objektů. Pro shlukování se používá řada metod, jednou z nejznámějších je například metoda UPGMA. Při ní se vytvoří shluk z objektů s nejnižší vzdáleností v matici podobností a následně je matice upravena, pro úpravu nově vytvořených hodnot se používá aritmetický průměr. Výsledkem takové analýzy je pak dendrogram. [11]

V této praktické části této práce jsou pro klasifikaci využity umělé neuronové sítě. Ty je vhodné použít v případech, kdy nelze přesně definovat pravidla pro ES nebo tyto pravidla nejsou vůbec známa, v našem případě například předem nevíme, jaké je relativní zastoupení toho či onoho frekvenčního pásma EEG pro jednotlivé spánkové fáze. Vývoj umělých neuronových sítí zaznamenal velký rozvoj v 80. letech a od té doby našly uplatnění v mnoha oborech. Jejich velkou předností je především schopnost sítě učit se, má zavedenou zpětnou vazbu, která síť oznámí, jak dobře splnila svůj úkol a podle toho se nastavení sítě upraví. [9]

Základní jednotkou neuronové sítě je neuron, nazývaný perceptron. Obdobně jako u biologických neuronů i zde se jedná o procesní prvek s více vstupy a jedním výstupem. Schéma neuronu vidíme na Obrázek 3.4. Proměnné x tvoří vektor příznaků a jsou vstupními hodnotami neuronu. Tyto hodnoty jsou váhovány vektorem vah w , funkce $f(\dots)$ je charakteristika neuronu. Důležitou charakteristikou neuronu je sigmoidální funkce, obvykle nabývá hodnot mezi -1 a 1, případně mezi 0 a 1, tato funkce je důležitá u dopředných sítí, využívaných v této práci. [9]



Obrázek 3.4 Schéma neuronu [9]

Jeden neuron se dvěma vstupy funguje jako klasifikátor tak, že přiřadí dvojici vstupních hodnot x_1 a x_2 do jednoho ze dvou prostorů v rovině, oddělených přímkou. Její rovnice je dána aktuálním nastavením vah a prahu neuronu. Pokud bychom chtěli prostor rozdělit lomenou čarou, budeme potřebovat dva paralelně pracující neurony, pokud bychom prostor dělili složitější křivkou, je nutné použít odpovídající počet neuronů. Počet vstupů neuronu pak udává dimenzi prostoru, v kterém klasifikujeme. Další již zmíněnou vlastností sítí je jejich schopnost učení. Sítě jsou předložena na vstup učební data, u nichž známe očekávaný výstup. Tato hodnota je porovnána s výstupem sítě a podle velikosti odchylky jsou upraveny váhy neuronů a proces se opakuje. Učení pak může obsahovat desítky a stovky takových učebních epoch (iterací), přičemž učení končí, dosáhne-li výsledek přijatelné chyby. Při sestavování neuronové sítě tak volíme několik parametrů. Prvním z nich je počet skrytých vrstev sítě a počet neuronů v nich. Dále volíme metodu učení sítě, v současnosti je dostupná řada algoritmů, které se liší rychlostí a vhodností použití pro různé typy dat. Důležité je také nastavit počet iterací, po kterých má být učení ukončeno a hranici výkonnosti sítě, nejčastěji vyjádřené hodnotou střední kvadratické chyby, po jejímž dosažení je učení ukončeno předčasně. [9]

Klasifikačních metod nicméně existuje celá řada a jejich popis přesahuje rámec této práce. Pro srovnání některých existujících metod klasifikace spánkových fází byla vytvořena Tabulka 3.1, ve které lze najít informace o druhu a původu klasifikovaných dat, o typu použité klasifikační metody a dosažené úspěšnosti klasifikace. Tabulka bude později sloužit rovněž pro srovnání s výsledky dosaženými v této práci.

Tabulka 3.1 Srovnání různých metod klasifikace spánkových fází z literatury

Rok vydání	Autor	Použitá data	Klasifikační příznaky	Metoda klasifikace	Klasifikované fáze	Úspěšnost
2012	Álvarez-Estévez [1]	SHHS databáze, 33 pacientů	průměrné a maximální hodnoty EMG a EOG, relativní zastoupení EEG pásem, detekování K-komplexy a spánková vřetena	Expertní systém, použití fuzzy rozhodování	W, N1, N2, N3, R	84%
2008	Ebrahimi [2]	databáze Physionet, 7 záznamů	energie jednotlivých EEG pásem zjištěná pomocí vlnkové transformace, průměrné hodnoty a směrodatné odchylky	Neuronové sítě	W, S1+R, S2, SWS	88-98%
2011	Fraiwan [4],	University of Heidelberg, 16 pacientů	získány časově-frekvenční parametry různými metodami	Náhodný les	W, N1, N2, N3, R	83%
1999	Oropesa [14]	2 záznamy EEG	zastoupení EEG pásem pomocí vlnkové transformace, detekce spánkových vřeten a K-komplexů, statistické parametry	Neuronové sítě	W, S1, S2, R	70-80%
2011	Ronzhina [15]	Sleep-EDF Database, 8 záznamů	relativní zastoupení EEG pásem + 30 pásem po 1Hz (0,5-30Hz)	Neuronové sítě	W, S1, S2, S3, S4, R	64-96%

4. Práce s PSG daty

Následující kapitola je již převážně praktická, je zde věnován prostor rozboru PSG dat, použitých pro pozdější klasifikaci spánkových fází. V jednotlivých podkapitolách bude provedena zběžná analýza dvou druhů signálů v časové, frekvenční a časově-frekvenční oblasti. Důraz bude kladen především na parametry, jež jsou vhodné pro automatickou klasifikaci spánkových fází, která je cílem praktické části diplomové práce.

4.1. Použitá data

V praktické části je pracováno s PSG daty, pocházejícími ze spánkové laboratoře Fakultní nemocnice u svaté Anny v Brně. Data byla naměřena již dříve, při studii RELIEF. Jedná se o studii, týkající se léčby pacientů s farmakoresistentní hypertenzí metodou ablace renálního sympatiku. Celkově bylo během studie zkoumáno asi 30 pacientů, z nichž pro

diplomovou práci byla k dispozici data od 10 z nich, značená čísla 001-010. Data byla původně uložena ve formátu EDF a obsahují 20-22 naměřených signálů, příklad je uveden v

Tabulka 4.1, kompletní tabulka je pak přiložena k diplomové práci v příloze A.

Tabulka 4.1 Úryvek ze seznamu kanálů, měřených během studie RELIEF (převzato a upraveno [3])


Zkratka kanálu	Popis kanálu	Vzorkovací frekvence Hz	Poznámky k snímání
Abdo	Břišní pás snímající úsilí břicha	32	Princip indukční pletysmografie
Airflow	Oronazální termočlánek	32	teplotně snímá proud vdechovaného a vydechovaného vzduchu důležité pro scoring apneí
C3M2	EEG kanál C3-M2	256	-
C4M1	EEG kanál C4-M1	256	-

Jak již bylo zmíněno, data byla původně uložena ve formátu EDF. Ten byl vyvinut na počátku 90. let, cílem bylo najít takový formát, který by umožňoval jednoduchou výměnu polysomnografických dat a aplikaci algoritmů pro jejich analýzu. Výsledkem byl European Data Format, jež byl poprvé publikován v roce 1992. Od té doby se stal standardem pro EEG a PSG záznamy. Formát v roce 2002 čekalo rozšíření na EDF+, který umožňuje uložení jakýchkoliv medicínských záznamů a řeší takové problémy, jako je například rozdíl mezi desetinnou čárkou a tečkou. [7]

Pro potřeby diplomové však byla data konvertována do formátu MAT, který je pro tyto potřeby vhodnější vzhledem k tomu, že data byla dále zpracovávána v MATLABu. Výsledkem je pak soubor, obsahující matici buněk o rozměrech 10x24 (resp. 10x22). V jednotlivých řádcích jsou uloženy informace, jako například název snímaného signálu, jednotka, použité filtry, vzorkovací frekvence a v poslední řadě samozřejmě samotná data. Poslední sloupec každého pole pak reprezentuje hotový hypnogram, který byl již dříve manuálně vytvořen. Tento hypnogram nabývá hodnot od 0 do 9 pro každý 30s úsek měření (tedy 1. hodnota pro 0-29s, 2. hodnota 30-59s atd.), hodnoty vyjadřují: 0 – wake, 1 – N1, 2 – N2, 3 – N3, 5 – REM, 9 – neklasifikováno. [3]

V praktické části je pracováno se třemi typy dat. Prvním je signál EEG, neboť ten je pro klasifikaci spánkových fází nejdůležitější. Pro přesnější rozlišení spánkových fází je však vhodné použít i jiné signály, jako třeba EOG, submentální EMG nebo EKG či dýchání. V tomto případě byly navíc použity signály EOG a EMG. EEG signál byl naměřen systémem elektrod,


jejichž rozmístění je vyobrazeno na Obrázek 4.1. Zpracováván byl v této kapitole signál ze svodu C4M1, podle doporučení AASM. [5]



Obrázek 4.1 Rozmístění elektrod pro snímání EEG v rámci studie RELIEF [3]

Pro analýzu EOG signálu byl použit svod E1, zaznamenávající okulogram levého oka. Elektroda umístěná vedle oka snímá signál vůči referenční elektrodě Fpz, její umístění je na Obrázek 4.1 (zelená elektroda). Signál EMG představuje záznam ze submentální oblasti, umístění elektrod odpovídá Obrázek 2.3 v předchozí kapitole. Všechny použité signály jsou vzorkovány na frekvenci 256Hz a byly předzpracovány NOTCH filtrem s frekvencí 50Hz.

Data od některých pacientů neobsahovala dostatečný počet N3 a REM fází (u jednoho pacienta dokonce žádné) a tak byly vyřazena jako nevhodné. K analýze v této kapitole byl pak použit soubor od náhodně vybraného pacienta číslo 006. Pro další analýzu byly signály rozděleny do tří sad po pěti maticích, kde každá matice obsahovala signály z jednotlivých spánkových fází, každý řádek matice představuje jednu 30ti sekundovou epochu. Ukázku signálů ukazuje Obrázek 4.2, použita byla náhodná epocha, klasifikovaná jako N2 fáze. Povšimnout si zde můžeme pohybu očí v kanálu EOG v páté sekundě, který se promítá i do signálu EEG, s opačnou polaritou výchylky. Takové náhodné pohyby se můžou vyskytovat častěji i u jiných fází a můžou působit problémy při automatické i manuální klasifikaci.



Obrázek 4.2 Ukázky signálů (fáze N2)


4.2. Práce se signálem v časové oblasti

První z možností, které se nabízí při práci se signálem, je jeho zpracování v časové oblasti. Zde jsou k výpočtům použity přímo hodnoty signálu, jako například při statistické analýze, která může být aplikována na PSG data. Pro tuto analýzu byly použity výpočty tří parametrů, zmíněných v podkapitole 3.1.


Všechny tyto parametry byly spočteny pro každou 30 sekundovou epochu signálu a jednotlivé výsledky byly přiřazeny do vektorů. Ty byly poté graficky znázorněny pomocí tzv. krabicových grafů, základní funkcí MATLABu *boxplot*. Tyto grafy poskytují základní představu o souboru hodnot, obdélník značí IQR - hodnoty mezi horním a dolním kvantilem, neboli 75 a 25 percentil. Čára (či jiná značka) v obdélníku představuje medián, tedy 50 percentil. „Vousy“ vycházející z obdélníků značí 1,5 násobky IQR, všechny hodnoty s vyšší vzdáleností jsou označeny samostatně jako odlehlé hodnoty.

Na Obrázek 4.3, Obrázek 4.4 a Obrázek 4.5 vidíme krabicové grafy středních hodnot tří signálů pro jednotlivé spánkové fáze. Na první pohled vidíme, že střední hodnota nebude vhodným parametrem pro klasifikaci spánkových fází. Hodnoty signálů oscilují kolem nuly bez tendence směřovat do kladných či záporných hodnot, jednotlivé krabicové grafy se výrazně


překrývají a tudíž by podle těchto hodnot nešla určit spánková fáze. Jistou hodnotu nám však grafy přece jenom přináší – u W fáze můžeme pozorovat u EOG signálu velké množství odlehlých hodnot. Tento jev je způsoben nepravidelným pohybem očí, který bdění, samozřejmě, doprovází. Rovněž u hodnot EMG vidíme menší rozsah hodnot u fáze REM. U této fáze lze očekávat nejnižších hodnot EMG, čehož by šlo využít, pokud bychom zpracovávali signál v kratším okně a hodnotili výchylku signálu.



Obrázek 4.3 Průměrné hodnoty signálu EEG




Obrázek 4.4 Průměrné hodnoty signálu EOG




Obrázek 4.5 Průměrné hodnoty signálu EMG


Následujících obrázky reprezentují krabicové grafy směrodatných odchylek a rozptylů. U signálu EEG si můžeme všimnout na Obrázek 4.6 a Obrázek 4.9 hodnot u fáze N3, které se nepřekrývají s ostatními hodnotami N a REM fází. Tohoto faktu by šlo využít, pokud bychom potřebovali zpřesnit klasifikaci fáze N3. Hodnoty získané ze signálů EOG na Obrázek 4.7 a Obrázek 4.10 se silně překrývají a pravděpodobně by nebylo vhodné tyto hodnoty použít pro klasifikaci. U fáze W si ale můžeme všimnout velkého množství odlehlých hodnot, způsobených nepravidelným pohybem očí, který bdění doprovází. Směrodatné odchylky signálu EMG podle Obrázek 4.8 a Obrázek 4.11 klesají s hlubším spánkem. Toho lze opět využít, pokud bychom aplikovali na signál kratší okno a hodnotili výchylku signálu v okně.




Obrázek 4.6 Směrodatné odchylky signálu EEG




Obrázek 4.7 Směrodatné odchylky signálu EOG




Obrázek 4.8 Směrodatné odchylky signálu EMG



Obrázek 4.9 Rozptyl signálu EEG



Obrázek 4.10 Rozptyl signálu EOG



Obrázek 4.11 Rozptyl signálu EMG


Máme-li pak výsledky této zjednodušené statistické analýzy shrnout, můžeme konstatovat, že střední hodnota se pro klasifikaci spánkových fází ze signálů EEG, EOG a EMG nehodí. Naopak další parametry popisující rozložení souborů hodnot by byly použitelné pro detekci fáze hlubokého spánku N3 za předpokladu, že bychom vyloučili fáze bdění a REM. U signálu EEG by pak tyto hodnoty pravděpodobně měly, vzhledem k rozložení, vyšší procento úspěšnosti detekce, neboť dochází k menšímu překryvu hodnot. Rovněž u signálu EMG by bylo možné použít hodnot směrodatné odchylky, neboť se grafy příliš nepřekrývají a mohly by nám pomoci rozlišit od sebe jednotlivé fáze N.

Nutno také podotknout, že při práci v časové oblasti nepracujeme pouze se statistickými parametry. Pro klasifikaci fáze N2 je užitečné detekovat K-komplexy v signálu EEG. Ty obvykle doprovází, spolu se spánkovými vřeteny, druhou fázi spánku N. K-komplex se projevuje jako ostrá, záporná vlna, následovaná kladnou, pomalejší vlnou, nejčastěji detekovaná na frontálních elektrodách. Celý jev by pak měl trvat déle než 0,5s. K-komplexy lze detekovat různými způsoby, od amplitudové detekce, přes detekci ve frekvenční oblasti až po detekci pomocí vlnek. V této práci ovšem detekce K-komplexů prováděna není a jak bude rozebíráno v následující podkapitole, se signálem EEG bude pracováno pouze ve frekvenční oblasti. [16],[17]

4.3. Práce se signálem ve frekvenční oblasti

Jak se ukázalo v předchozí podkapitole, časová oblast není, až na výjimky, příliš vhodná pro klasifikaci spánkových fází ze signálu EEG. Na druhou stranu je však známo, že v závislosti na stádiu bdělosti a spánku se mění spektrální vlastnosti EEG. Proto je vhodné převést signál do frekvenční oblasti pomocí některé z metod odhadu spektra. [15]

V diplomové práci byla pro výpočet PSD jednotlivých spánkových epoch použita funkce MATLABu `pwelch`, která odhaduje periodogram Welchovou metodou, zmíněnou ve třetí kapitole. Velikost okna byla zvolena 4 sekundy (1024 vzorků), což by mělo být dostatečně velké okno pro detekci nízkých frekvencí. Překryv obdélníkového okna byl zvolen 50%. Obrázek 4.12 zobrazuje dva různé průběhy PSD, pro srovnání vykreslené do jednoho grafu. Jedná se o PSD fázi bdělosti a hlubokého spánku N3, tedy dvou fází, u kterých se dá očekávat největší rozdíl ve spektrálním složení. Epochy byly zvoleny náhodně. Na první pohled je zřejmé, že při bdělosti jsou dominantní vyšší frekvence (alfa a beta rytmus), zatímco u modré křivky hlubokého spánku převažují nejnižší frekvence delta, tedy frekvence 0 – 4 Hz.




Obrázek 4.12 Porovnání PSD fází W a N3


Cílem této části práce bylo vytvoření grafů na Obrázek 4.13 a Obrázek 4.14. Na nich lze totiž pozorovat kmitočtovou závislost jednotlivých spánkových fází. Nejjednodušší se na první pohled zdá rozlišení fáze hlubokého spánku N3. Ta je z velké většiny tvořena delta

rytmem a ostatní frekvenční složky nejsou tolik výrazné. Spolu s předchozími zjištěními lze tedy usuzovat, že algoritmus pro detekci fáze N3 by měl být zaměřen na detekci delta rytmu EEG a pro zpřesnění lze doplnit statistickou analýzou v časové oblasti. Fázi bdění a N1 lze poznat podle vysokého procenta alfa rytmu, pro odlišení těchto dvou fází bychom však museli použít dalších podmínek. Zbývající fáze N2 a REM se vyznačují vyšším zastoupením frekvencí do 8Hz, jejich odlišení tak může být při použití pouze frekvenčních parametrů obtížné.

Pro vytvoření následujících krabicových grafů byly využity hodnoty z již provedeného odhadu periodogramu Welchovou metodou. Následně bylo spočítáno procentuální zastoupení jednotlivých EEG rytmů ve spektru, pro beta rytmus byla zvolena horní hranice 30Hz.



Obrázek 4.13 Zastoupení delta a theta rytmu ve spektru



Obrázek 4.14 Zastoupení alfa a beta rytmu ve spektru


Tuto podkapitolu tak lze shrnout tím, že frekvenční analýza je vhodným prostředkem pro klasifikaci spánkových fází, pro vyšší zpřesnění klasifikace je pak vhodné použít i jiných metod, jako například statistické analýzy, či doplněním o analýzu dalších signálů, jež by v polysomnografickém záznamu měly být dostupné

4.4. Práce se signálem v časově-frekvenční oblasti

Předchozí podkapitola byla věnována analýze EEG signálu ve frekvenční oblasti. Převod signálu FT na jeho spektrum nám sice přináší dostatek informací o frekvenčním složení signálu, nevypovídá ale nijak o jeho změnách a vývoji v čase. Pro vývoj algoritmu by se 30s spektra mohla zdát dostačující a ve většině případů tomu tak skutečně je, při manuálním výběru spánkové fáze však není od věci mít přehled o vývoji spektrálního složení signálu v průběhu dané epochy.


Jednou z možností, jak si udělat představu o vývoji spektra v čase je vytvoření spektrogramu pomocí STFT, zmíněné již v předchozí kapitole. Pro vytvoření spektra byla využita funkce *spektrogram* s velikostí okna 512 vzorků a polovičním překryvem okna. Tato velikost pokrývá délku signálu 2s, což je dostatečná délka pro detekci frekvencí 0,5Hz a vyšších, v našem případě byl signál předzpracován filtrem HP s mezní frekvencí 0,3Hz, lepší frekvenční rozlišení by tedy nemělo smysl a zhoršilo by se zbytečně rozlišení časové.

Příkladem spektrogramu je Obrázek 4.15. Pro jeho vytvoření byla použita náhodná epocha odpovídající fázi W, použité parametry byly popsány výše. Barevná škála vedle obrázku představuje zastoupení jednotlivých frekvencí ve spektrogramech v dB, nejlépe vidíme přítomnost alfa rytmu v oblasti kolem 10Hz. Na spektrogramu lze pozorovat i filtry použité v předzpracování. Nejlépe je viditelné použití NOTCH filtru o frekvenci 50Hz, kdy u této frekvence pozorujeme modrou oblast.




Obrázek 4.15 Ukázka spektrogramu (fáze W)

Na Obrázek 4.16 vidíme srovnání dvou spektrogramů. Levý spektrogram představuje fázi hlubokého spánku N3, pravý pak fázi bdění. Zde je patrné to, co bylo potvrzeno již v předchozí podkapitole. Pro zvýraznění oblasti zájmu byly proti předchozímu spektrogramu zobrazeny pouze frekvence do 40 Hz. Fáze N3 je typická přítomností delta vln a převážně je zastoupena frekvencemi do 4Hz. Proti tomu fáze bdění je typická přítomností vyšších frekvencí, podle přítomnosti alfa rytmu lze usoudit, že pacient bdí, ale má zavřené oči. Všechny tyto úkazy jsou patrné i z PSD v předchozí podkapitole. Spektrogram ale díky použité barevné škále předává informaci v podobě, která je pro náš mozek mnohem srozumitelnější a jednodušší.



Obrázek 4.16 Srovnání dvou spektrogramů

Poslední dvě ukázky spektrogramů jsou zachyceny na Obrázek 4.17. Obě 30 epochy byly podle směrnic vyhodnoceny jako fáze bdělosti. V prvním případě je zřejmé, že pacient v prvních 10s epochy spal (předchozí epocha byla vyhodnocena jako N2), následně se ale objeví vyšší frekvence a tak je epocha vyhodnocena jako fáze W. Ve druhém případě je situace opačná, v prvních 16 sekundách je přítomen alfa rytmus, následně ale pacient upadá do hlubokého spánku, což lze poznat podle delta rytmu.



Obrázek 4.17 Dva spektrogramy s přechody mezi fázemi

Poslední spektrogramy výborně poukazují na problematiku standardu AASM, podle AASM se spánek vyhodnocuje ve 30-sekundových epochách a řídí se podle souboru rozhodovacích pravidel. V obou případech bylo pravděpodobně rozhodnuto podle pravidla A v manuálu AASM, který definuje, že epocha je vyhodnocena jako fáze W tehdy, pokud je detekován alfa rytmus ve více než 50% epochy. Jinými slovy vyhrála ta fáze, která trvala déle. Podle AASM byla samozřejmě epocha vyhodnocena správně, nicméně je na tomto příkladu vidět, že vyhodnocováním z 30s epoch dosahuje hypnogram poměrně nízkého časového rozlišení. [5]

V dnešní době se již objevují studie, ve kterých je snaha o skórování PSG dat s daleko vyšším časovým rozlišením. Jednou z takových možností je nahrazení některých signálů pomocnými signály s pomocí třisekundového okna s překryvem. Získáme tak například hodnoty relativní PSD pro jednotlivé EEG rytmy nebo amplitudový signál z EMG a EOG. Aplikací souboru rozhodovacích pravidel je pak možné vyhodnotit tyto signály a pro každý okamžik určit aktuální hodnotu hypnogramu. Tím je možno získat téměř kontinuální hypnogram s mnohonásobně vyšším časovým rozlišením. V dobách manuálního vyhodnocování spánkových studií by takový přístup byl časově nerealizovatelný, v dnešní době je však hodnocení *in continuum* proveditelné a je možné, že se tímto směrem bude hodnocení PSG dat v budoucnu ubírat. Právě z tohoto důvodu jsem se také rozhodl použít výše zmíněnou metodu třisekundového okna s překryvem dvě sekundy pro samotnou klasifikaci spánkových fází v následující kapitole. [1]

5. Klasifikace spánkových fází

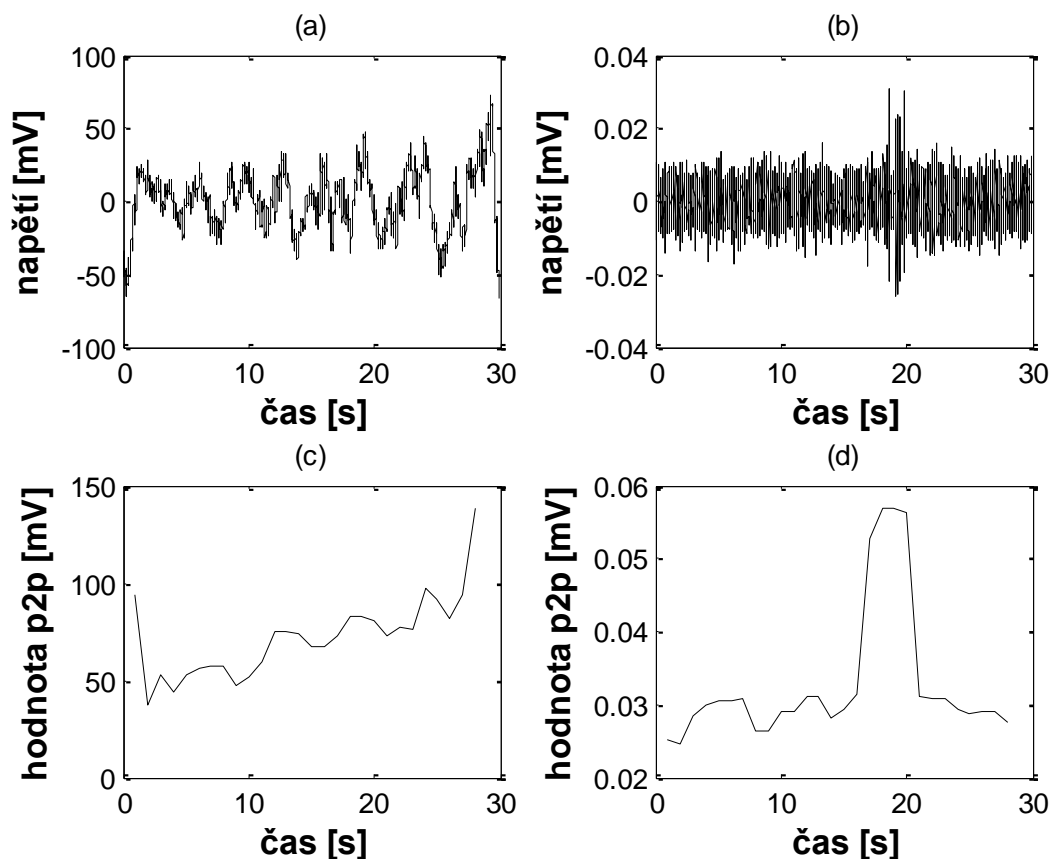
Jak již bylo zmíněno, časové rozlišení třiceti sekund při klasifikaci spánkových dat je sice dostatečné, v některých případech by však mohlo být mnohem užitečnější, kdybychom měli přehled o vývoji spánku s vyšším časovým rozlišením, především tedy v oblastech přechodu mezi fázemi. Proto je samotná klasifikace spánkových fází v této práci prováděna s rozlišením jedné sekundy. Pro takovou klasifikaci je nutné získat v každé sekundě spánku dostatečné množství parametrů – klasifikačních příznaků, v tomto případě je aplikován postup z dříve zmíněné studie a následně jsou klasifikační příznaky vyhodnocovány pomocí neuronových sítí. [1]

5.1. Vytvoření klasifikačních příznaků a neuronové sítě

Pro získání parametrů, potřebných pro klasifikaci spánkových fází bylo použito celkem pět signálů z dat od čtyř z deseti dostupných pacientů. Data od zbylých šesti pacientů

nebyla použita převážně proto, že u nich byl vyhodnocen nedostatečný počet některých spánkových fází, a tudíž by nebylo možné data od těchto pacientů použít k učení neuronových sítí. Použity byly tři signály EEG – svody Fz-Cz, C₃M₂ a Cz-Oz, dále oba svody EOG a submentální EMG.


Signály EOG a EMG byly zpracovány stejným způsobem. Použity byly již existující matice, vytvořené pro účely předchozí kapitoly, kde každá matice představuje všechny epochy dané fáze vybraného signálu. Následně bylo aplikováno posuvné okno délky tři sekundy (768 vzorků) s překryvem dvě sekundy, v kterém byla pomocí funkce *peak2peak* zjištěna hodnota maximální výchylky v okně. Tím bylo pro každý řádek matice vypočteno 28 hodnot, celkově tedy byly získány tři sady parametrů. Ukázkou výsledných parametrů v porovnání s původním signálem z jedné epochy N1 ukazuje Obrázek 5.1. Na něm vidíme, jak vývoj parametru popisující výchylku signálu koresponduje se skutečným signálem, kdy u EOG vidíme nárůst výchylky v průběhu epochy.



Obrázek 5.1 Ukázka původního signálu EOG (a), EMG (b) a vypočtených parametrů pro EOG (c) a EMG (d)


Se signálem EEG bylo pracováno v časově-frekvenční oblasti. Opět bylo využito rozdělení signálu na spánkové fáze z předchozí části. V každé epoše byl vypočítán spektrogram s parametry okna stejnými, jako v případě signálů EOG a EMG. Pro každou sekundu pak bylo

ze spektrogramu získáno relativní zastoupení jednotlivých spánkových rytmů, celkem tedy pro tři svody EEG tři sady parametrů pDelta, pTheta, pAlfa a pBeta, celkem tedy dvanáct parametrů pro EEG, dva parametry pro EOG a jeden pro EMG. Ukázkou získaných klasifikačních příznaků pro EEG z jednoho svodu a jejich vývoj v průběhu jedné epochy vidíme na Obrázek 5.2, zde je viditelný i přechod mezi dvěma spánkovými fázemi.



Obrázek 5.2 Ukázka parametrů pro EEG

Samotná klasifikace proběhla pomocí neuronové sítě, vytvořené v programovém prostředí MATLAB (verze 2009b). Jedná se o jednoduchou dopřednou síť s jedním výstupním neuronem s lineární aktivací. Síť má dvě skryté vrstvy s proměnlivým počtem neuronů v každé z nich, v první vrstvě bylo použito 13-23 neuronů, v druhé 5-9, testována byla každá kombinace, jejich aktivací funkce je sigmoidální. Schéma neuronové sítě ukazuje Obrázek 5.3.



Obrázek 5.3 Schéma použité neuronové sítě

Při učení neuronové sítě byl nastaven maximální počet učebních iterací 500, krok učení 0,01 a cílová hodnota kvadratické chyby (MSE) 0,01. Pro srovnání byly použity tři metody učení:

- *trainlm* – Levenberg-Marquardt (LM), obvykle nejrychlejší algoritmus, nastavený jako defaultní,
- *trainbfg* – BFGS quasi-Newtonova metoda zpětné propagace (BFG), další z rychlých algoritmů, jeho náročnost ale kvadraticky narůstá s počtem proměnných,

- *traingdx* – metoda gradientního sestupu, nejpomalejší z použitých algoritmů, rychlost učení je adaptivní v závislosti na výkonnosti sítě v předchozí epoše (vyjádřené hodnotou MSE).

Velikosti množin učebních a testovacích dat se lišily v závislosti na počtu klasifikovaných fází. Učební množina byla vždy vytvářena z 280 vektorů parametrů pro každou klasifikovanou fázi, testovací množina pak pro každou fázi obsahovala 56 náhodně vybraných vektorů o 15 parametrech. Učební a testovací data se nepřekrývala, byly použity celkem 4 různé přístupy k původu učebních a testovacích dat - data pro učení a testování od stejného pacienta a tři varianty kdy jsou učební data od jiného pacienta než data testovací a kdy učební data pochází od jednoho, dvou a tří pacientů.

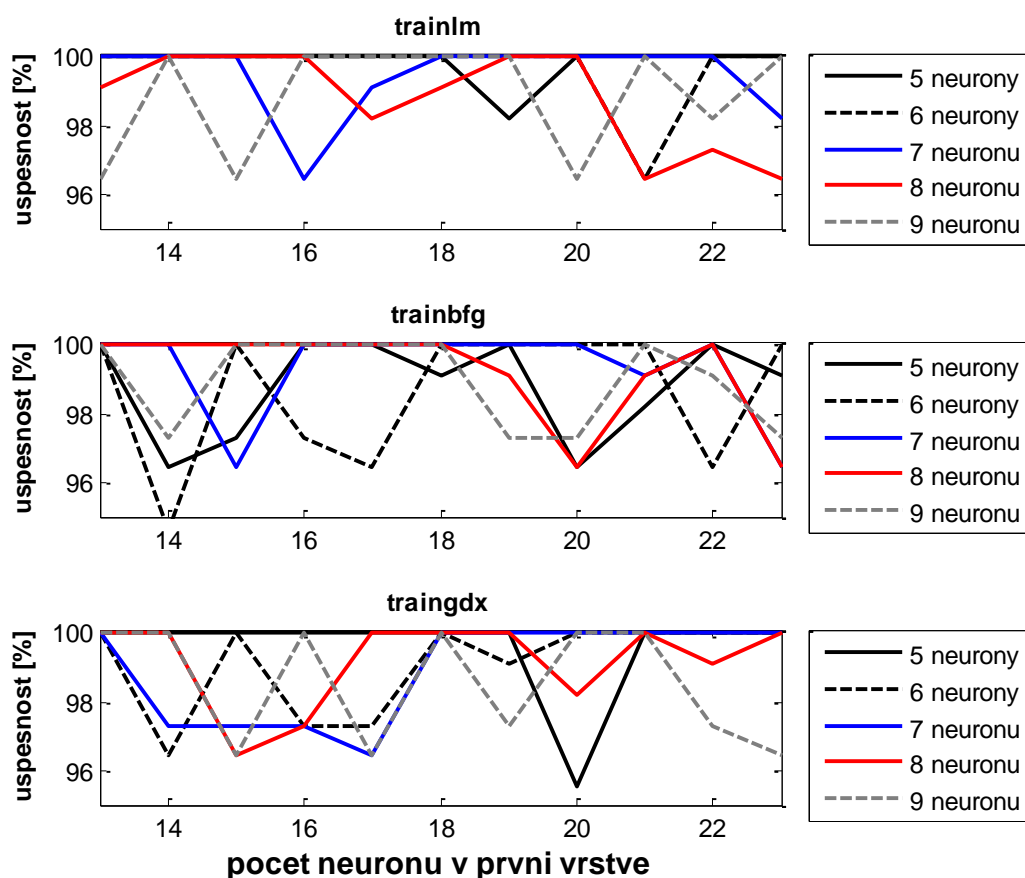
V každé podkapitole jsou spánková data klasifikována ve třech variantách. Nejjednodušší a dle očekávání nejúspěšnější je rozlišování fází wake a nonREM3. Vzhledem k tomu, že se jedná o nejodlišnější fáze spánku lze očekávat, že použitá neuronová síť nebude mít problém tyto fáze rozlišit. Dále je přidána REM fáze, která je v mnohých ohledech podobná fázi N3 a tak již může docházet k nesprávné klasifikaci. V poslední fázi jsou klasifikovány všechny fáze. Vzhledem k velké podobnosti fází N1 a N2 a také N1 a W lze očekávat, že dosažené výsledky budou horší než v předchozích případech.

5.2. Data od jednoho pacienta

Nejjednodušším způsobem, jak získat učební a testovací data, je použít data od jednoho pacienta tak, aby se obě množiny nepřekrývaly. Dá se očekávat, že takový přístup přinese dobré výsledky, nicméně v klinické praxi by použití tohoto přístupu bylo značně nepraktické. Vyžadovalo by totiž manuální vyhodnocení dat do doby, než bychom získali dostatečné množství dat pro každou klasifikovanou fázi, abychom mohli neuronovou síť naučit. Data použitá v této práci jsou ale již skórovaná a tak je vhodné tímto přístupem začít. Pro tuto kapitolu byla použita data od pacienta č. 010.

V první části byla provedena klasifikací fází W a N3. Již bylo zmíněno, že učení a testování probíhalo pro každou kombinaci počtu neuronů v první a druhé vrstvě a rovněž pro tři různé učební metody. Pro učení sítě byly vybrány parametry reprezentující 280s záznamu pro fázi W a stejnou délku záznamu pro fázi N3, fáze W byla na výstupu hodnocena jako 0, fáze N3 jako 1. Výsledky z tohoto testování vidíme na Obrázek 5.4. Na první pohled není velký rozdíl v úspěšnostech pro jednotlivé kombinace počtu neuronů ani pro různé učební metody. Ve všech případech bylo dosaženo úspěšnosti klasifikace 95-100%, za nejvýhodnější nastavení druhé skryté vrstvy lze považovat u všech metod počet sedmi neuronů, počet neuronů v první vrstvě se liší v závislosti na použité metodě. Znatelný byl ale rozdíl v době výpočtu. Zatímco metody LM a BFG končily učení po 5-20 iteracích, metoda gradientního sestupu vyžadovala


pro dosažení hodnoty střední kvadratické chyby až 150 iterací, čímž se samozřejmě znatelně prodloužila výpočetní doba pro všech 50 kombinací.



Obrázek 5.4 Výsledky testování různých nastavení neuronových sítí (fáze W a N3, pacient 010)

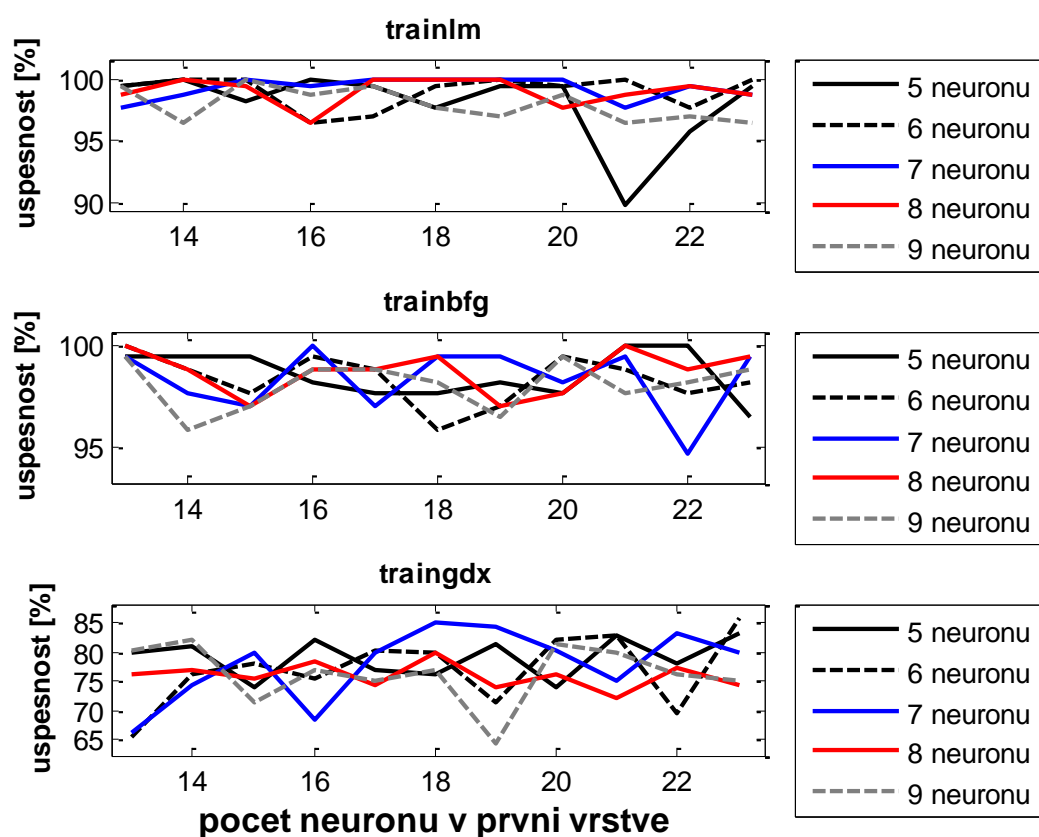
Pro každou metodu učení byla vybrána jedna kombinace počtu neuronů s nejvyšší úspěšností. Vzhledem k vysokým hodnotám u více případů byla pro všechny tři metody zvolena kombinace 20-7, kde první číslo vyjadřuje počet neuronů v první skryté vrstvě a druhé číslo počet neuronů ve vrstvě druhé. Následně bylo provedeno dvacet nových a na sobě nezávislých učení a testování neuronové sítě s tímto nastavením, výsledné hodnoty tak poslouží k lepšímu statistickému pohledu na klasifikaci, neboť bude lépe vyloučen vliv náhodného nastavení výchozích váhových a prahových hodnot jednotlivých neuronů. Výsledné boxploty pro všechny tři metody učení vidíme na Obrázek 5.5. Pro metody LM a BFG lze z boxplotu vyčíst, že bylo testování úspěšné na 100%, vyjma jednoho, respektive dvou případů, které v boxplotu vystupují jako odlehlé hodnoty. Proti tomu u metody GDX pozorujeme větší počet hodnot v rozmezí 97-100%. Vzhledem ke zmiňované vyšší výpočetní náročnosti lze tak první dvě metody učení v tomto případě považovat za vhodnější. Rovněž je vhodné se podívat, na které fázi klasifikace selhávala. Ve všech případech byla fáze N3 klasifikována správně. K selhání tedy docházelo u fáze W, která byla v nejhorším případě čtyřikrát klasifikována jako N3. Na vině budou nejspíše

rozdíly mezi fázemi W v průběhu noci, neboť některé z učebních fází W pochází z doby před prvním usnutím, kde mohlo docházet například ke vzniku artefaktu způsobeného pohybem očí.




Obrázek 5.5 Výsledky opakovaného učení a testování nejlepšího nastavení neuronové sítě (fáze W a N3, pacient 010)

V další části byly z dat od jednoho pacienta klasifikovány tři spánkové fáze: W, N3 a REM. Ačkoliv se stále jedná o dosti odlišné spánkové fáze, lze očekávat, že se úspěšnost klasifikace sníží, kvůli podobnostem mezi fází REM a zbylými dvěma fázemi. Učební množina byla opět tvořena 280 vektory 15 parametrů pro každou klasifikovanou fázi. Fáze W, N3 a REM byly na výstupu reprezentovány hodnotami 0, 1 a 2. Výsledky testování pro všechny kombinace počtu neuronů ve skrytých vrstvách vidíme na Obrázek 5.6. Z prvního a druhého grafu pozorujeme, že se úspěšnost klasifikace přidáním další fáze příliš nezhoršila, k poklesu došlo jen v ojedinělých případech. Naopak u metody gradientního sestupu došlo k pozorovatelnému zhoršení klasifikace, i přesto se však stále pohybovala v hodnotách přes 90%. Zatímco při použití metody LM nedošlo k výraznějšímu nárůstu výpočetní doby, u metody učení BFG již bylo znatelné zvětšení učební množiny o dalších 280 vektorů parametrů, pro dosažení hodnoty MSE 0,01 bylo potřeba až 100 iterací. Déle probíhalo i učení metodou GDX, zde bylo ovšem prodloužení doby výpočtu úměrné zvětšení učební množiny.



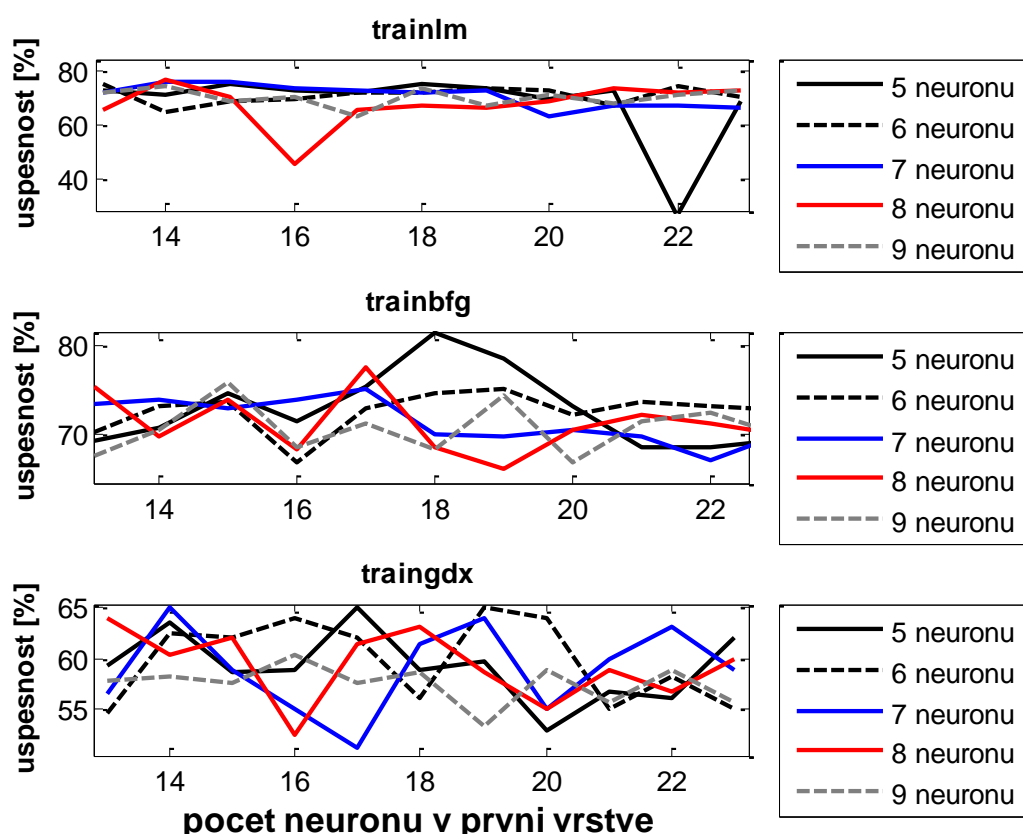
Obrázek 5.6 Výsledky testování různých nastavení neuronových sítí (fáze W, N3, R, pacient 010)

Pro jednotlivé metody učení byly vybrány nastavení počtu neuronů ve skrytých vrstvách 18-7, 16-7 a 17-6. Následně bylo opět provedeno dvacet nových učení a testování sítí a výsledky prezentovány boxploty. Ty můžeme vidět na Obrázek 5.7. Z grafu je jednoznačně patrné, že nejhorší výsledky má síť učená metodou gradientního sestupu, s nejčastějšími hodnotami 92-95%. O poznání lépe dopadla metoda BFGS quasi-Newton, s mediánem 98%. Jako nejvhodnější metoda pak vychází základní nastavení, učení metodou Levenberg-Marquardt, která nejen že dosahuje téměř 100% výsledků, ale rovněž vychází nejlépe z hlediska časové a výpočetní náročnosti, neboť pro naučení i přes vyšší počet dat potřebovala v průměru 10 iterací.




Obrázek 5.7 Výsledky opakovaného učení a testování nejlepšího nastavení neuronové sítě (fáze W, N3 a R, pacient 010)

V poslední části podkapitoly bylo klasifikováno všech pět spánkových fází. Vzhledem k tomu, že nastavení neuronových sítí zůstává stejné a vzhledem k tendenci, kterou jsme pozorovali v předchozí části lze očekávat, že se úspěšnost klasifikace přidáním dalších dvou spánkových fází dále sníží. Pro učení neuronové sítě byla použita matice 1400x15, testovací data byla vytvořena z 280 sad 15 parametrů. Na výstupu neuronové sítě pak byly získány hodnoty 0, 1, 2, 3 a 4 pro fáze W, N1, N2, N3 a REM. Výsledky klasifikací pro různé nastavení počtu neuronů reprezentuje Obrázek 5.8. Již na první pohled je zřetelné zhoršení úspěšnosti o desítky procent. Sítě učené metodami Levenberg-Marquardt a BFGS quasi-Newton lze zhodnocením z grafů považovat za úspěšnější, než sítě učené přes gradientní sestup. Je ovšem nutné ještě uvažovat náročnost výpočtu. U metod LM i GDX pochopitelně zvětšením vstupní matice narostla doba pro výpočet, v tomto případě ale byla dána především tím, že pro učení bylo potřeba všech 500 iterací a i tak bylo dosaženo hodnot MSE kolem 0,05-0,1. U metody BFG se však viditelně prodloužila doba výpočtu jedné iterace a tak celý proces učení jedné sítě trval až dvě minuty, tedy zhruba 100 minut pro všech 50 kombinací.



Obrázek 5.8 Výsledky testování různých nastavení neuronových sítí (všechny fáze, pacient 010)

Obrázek 5.9 znázorňuje výsledky opakovaného učení a testování nejlepší možné konfigurace sítí. Pro jednotlivé metody bylo použito nastavení: LM 18-5, BFG 18-5 a GDX 19-6. Výsledky jsou poněkud překvapivé, quasi-Newtonova metoda dosáhla lepších výsledků než defaultní Levenberg-Marquardt, což neodpovídá trendu z předchozí části. Je tak možné, že přidání dvou fází N1 a N2 bylo pro jednoduchý algoritmus LM příliš komplikované a neuronová síť učená metodou BFG si tak lépe poradila s novými, podobnými fázemi, byť za cenu delšího výpočtu. Podíváme-li se podrobněji, které fáze byly pro neuronovou síť problematické klasifikovat, potvrdí se nám předpoklad, že se jedná o podobné fáze N1 a N2. Fáze N1 byla jako N2 klasifikována často ve více, než polovině případů, obdobně na tom byla opačná situace. Zbylé tři spánkové fáze proti tomu byly zaměněny za jinou fázi pouze v minimu případů. Řešením této situace by mohlo být buď sloučení fází N1 a N2 do jedné, učení neuronové sítě daty od více různých pacientů nebo přidání dalších parametrů, ať už ze stejných nebo jiných signálů.



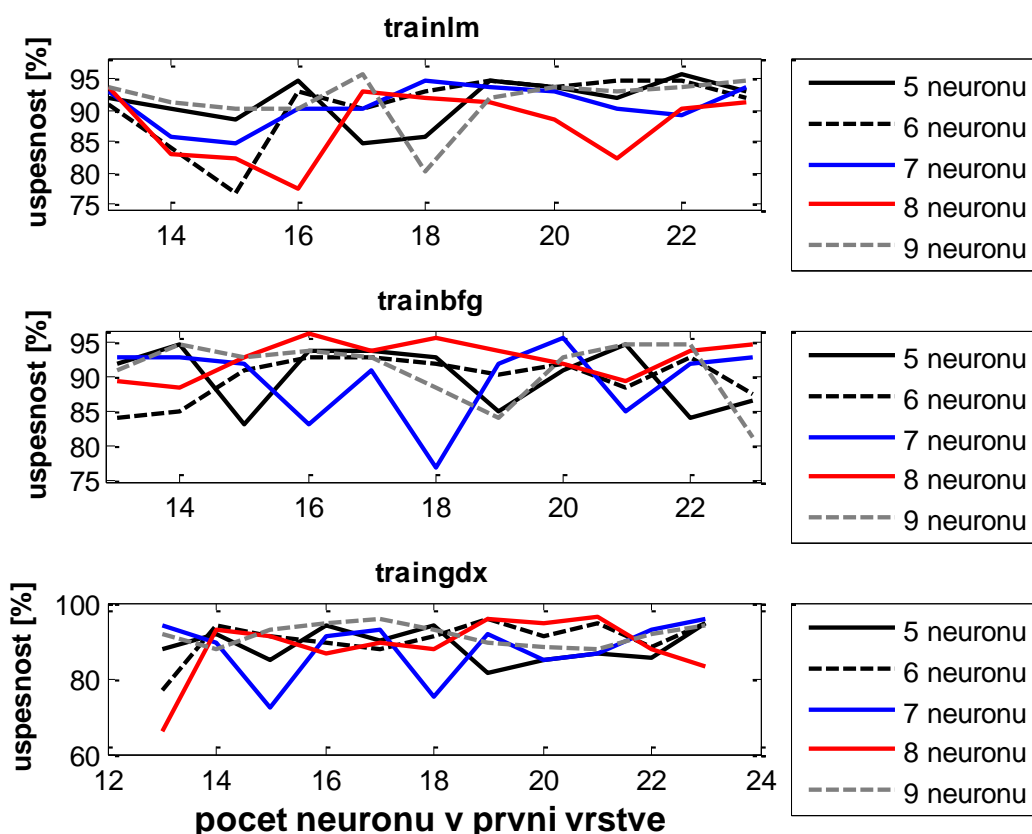
Obrázek 5.9 Výsledky opakovaného učení a testování nejlepšího nastavení neuronové sítě (všechny fáze, pacient 010)

5.3. Data od dvou pacientů

Další podkapitoly se věnují případům, kdy pro trénování a testování sítě použijeme data od více pacientů. V tomto případě je postupováno tak, že učební a testovací data pochází od dvou různých pacientů. Tento přístup má dvě výhody. Zaprvé je to jistota, že se učební a testovací množina dat nebude překrývat, což muselo být v předchozím případě ošetřeno. Zadruhé je tento přístup mnohem reálnější, co se týče použití v klinické praxi. Neuronovou síť by bylo možno naučit předem, na datech od vhodného pacienta a poté tuto naučenou síť používat pro klasifikaci dalších pacientů. S tím ale přichází i nevýhoda tohoto přístupu. Pokud bychom nenašli pro učení pacienta, který by vykazoval všechny typické znaky jednotlivých spánkových fází, bylo by velmi pravděpodobné, že u jiných pacientů by klasifikátor selhával, ať už ve více či méně případech. Vzhledem k tomu, že data použitá pro diplomovou práci pochází od pacientů, léčených na poruchy spánku, lze předpokládat, že dosažená úspěšnost klasifikace bude nižší, než v předchozí podkapitole.


Pro tuto podkapitolu byla vybrána data od pacienta 010 jako učební (tedy stejný původ učebních dat jako v předchozí podkapitole) a od pacienta 007 jako testovací. V první části byly opět klasifikovány pouze dvě fáze, W a N3, tedy bdělost a hluboký spánek. Velikosti učebních matic byly voleny stejně jako v předchozí podkapitole, stejně tak se shodují další parametry neuronové sítě. Grafy úspěšností klasifikace pro jednotlivá nastavení počtu neuronů ve skrytých

vrstvách a pro tři různé metody učení vidíme na Obrázek 5.10. Z grafů lze vyčíst, že se úspěšnost klasifikace dle předpokladů snížila. Přestože v některých případech se výsledky blížily stoprocentní hodnotě, pohybovala se úspěšnost klasifikace především mezi hodnotami 80-90%.



Obrázek 5.10 Výsledky testování různých nastavení neuronových sítí (fáze W a N3, pacienti 010 a 007)

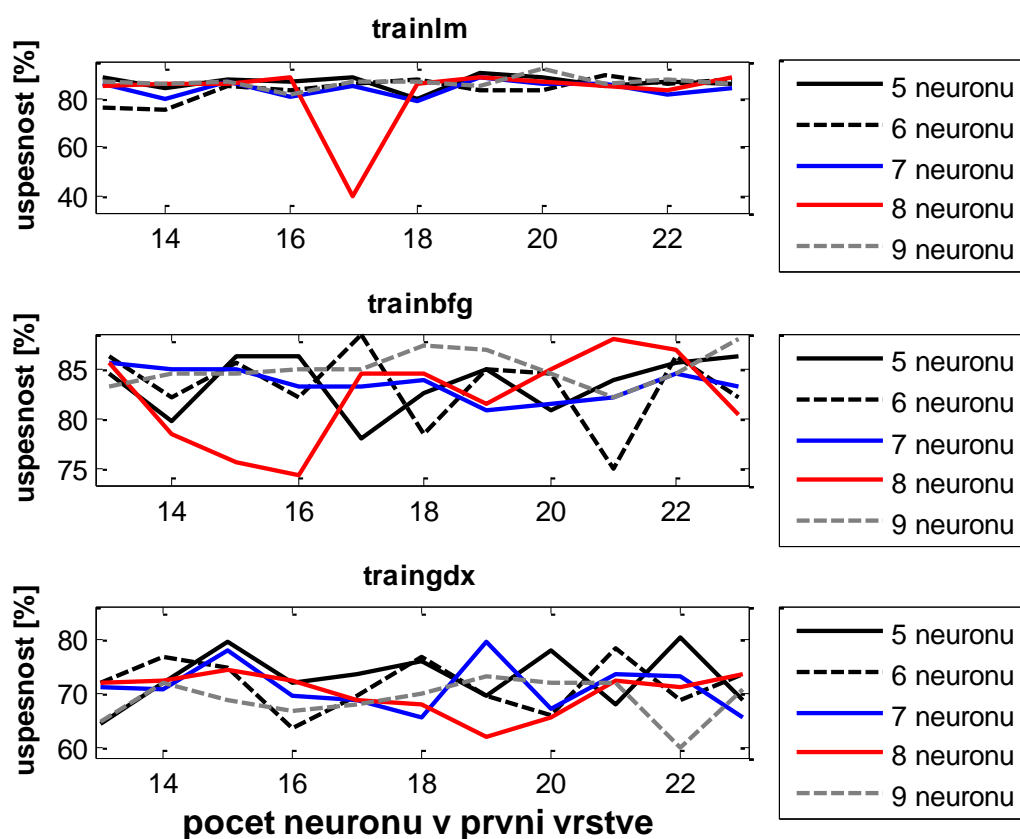
Pro učební metody LM, BFG a GDX byly jako nejvhodnější podle dosažených výsledků zvoleny počty neuronů ve skrytých vrstvách 5-22, 16-8 respektive 21-8. Stejně jako dříve bylo provedeno dvacet nových učení a testování sítí pro získání objektivnějšího statistického výsledku. Krabicový graf těchto opakování představuje Obrázek 5.11. Tyto grafy nám potvrzují výše zjištěný fakt zhoršení úspěšnosti klasifikace proti případu, kdy jsme pro učení i testování použili data od jednoho pacienta. Proti tomuto případu již hodnoty nevychází většinou 100%, ale jsou rozloženy mezi hodnotami 85-95%. Učební metoda Levenberg-Marquardt se z grafů jeví jako nejvýhodnější, neboť úspěšnost klesá pod 85% jen jednou odlehlou hodnotou, ostatní metody však vychází hůře jen v řádu procent a tak by byly rovněž vhodné pro učení neuronové sítě. Vzhledem k výpočetním nárokům by však bylo nejvýhodnější přiklonit se právě k metodě Levenberg-Marquardt.



Obrázek 5.11 Výsledky opakovaného učení a testování nejlepšího nastavení neuronové sítě (fáze W a N3, pacienti 010 a 007)


Dalším zajímavým faktem je, že zatímco v předchozí podkapitole klasifikace selhávala u fáze W a chybně ji klasifikovala jako N3, zde je situace jiná. U neúspěšnější metody LM bylo z 560 fází W chybně klasifikováno 26, tedy 4,6%. Z 560 fází N3 klasifikátor selhal ve 27 případech, tedy 4,8%. Na rozdíl od předchozího případu je tedy zde procento selhání stejné.

V druhé části byla ke klasifikaci přidána fáze REM. Pro učení byla opět použita matice parametrů od pacienta 010 o rozměrech 840x15, testovací matice od pacienta 007 o velikosti 168x15. Výsledky testování pro všechny kombinace nastavení neuronové sítě můžeme vidět na Obrázek 5.12. Grafy naznačují, že zatímco metody učení LM a BFG vykazují téměř shodné výsledky s hodnotami 80-90%, neuronové sítě učené metodou gradientního sestupu selhávají v průměru v 30% případů. Příčina tak nízkých výsledků je v tom, že sítě tohoto typu nedosáhly hodnoty MSE 0,01 ani po nastavených 500 iteracích. Řešením by mohlo být zvýšení počtu iterací pro tuto konkrétní metodu učení. Tím by však vzrostly nároky na výpočet při dosažení pouze minimálního zlepšení (přibližně 0,005 po dalších 100 iteracích)



Obrázek 5.12 Výsledky testování různých nastavení neuronových sítí (fáze W, N3, REM, pacienti 010 a 007)

Výsledky opakovaného testování nejlepšího nastavení vidíme na Obrázek 5.13. Použito bylo nastavení 20-9 pro metodu LM, 18-9 pro BFG a 19-7 pro GDX. Vidíme, že grafy mají podobné rozložení jako na Obrázek 5.7 v předchozí podkapitole, pouze v nižších hodnotách. Potvrzuje se zde tedy, že přidáním fáze REM pro klasifikaci začnou více selhávat sítě, učené metodou gradientního sestupu. Nejlepších výsledků opět dosáhly sítě učené metodou Levenberg-Marquardt s horním a dolním kvantilem mezi 85 a 90%. Nejedná se o velkou úspěšnost, nutno ovšem pamatovat na to, že ze všech případů použití dat od více pacientů se v tomto případě očekává nižší úspěšnost klasifikace.



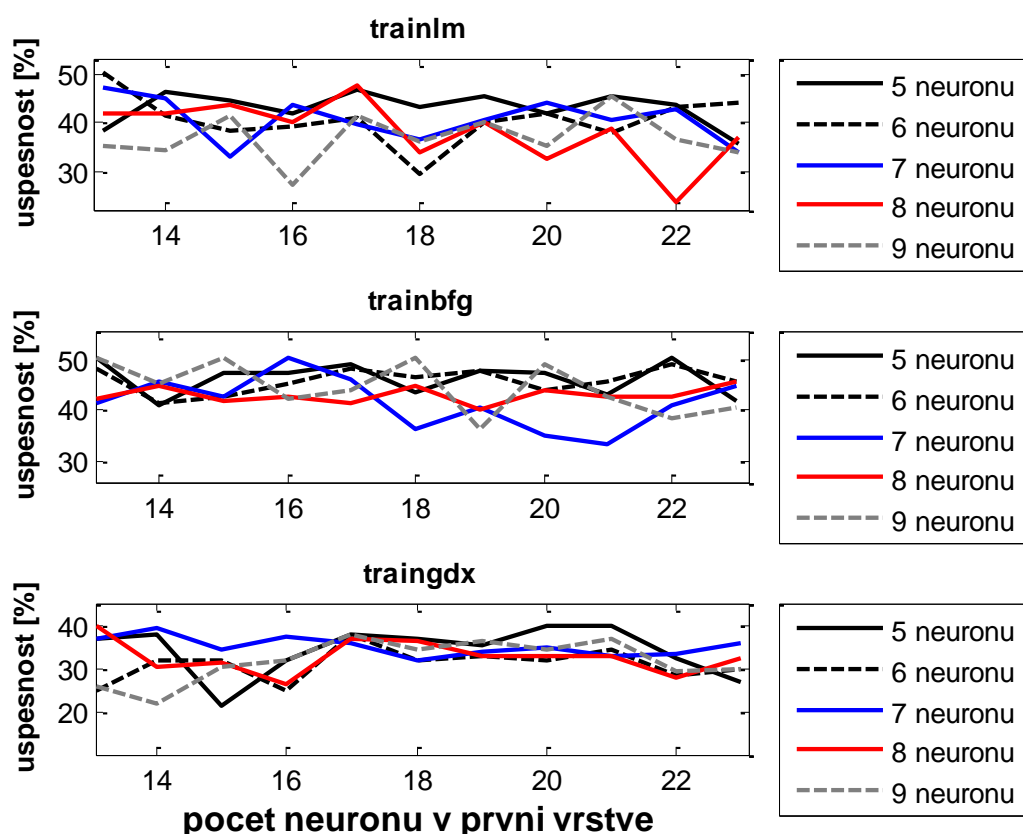
Obrázek 5.13 Výsledky opakovaného učení a testování nejlepšího nastavení neuronové sítě (fáze W, N3, REM, pacienti 010 a 007)

Následující Tabulka 5.1 ukazuje zjednodušenou matici záměn, vyjadřující počet správně a nesprávně klasifikovaných testovacích vektorů. Jedná se o výběr deseti výše hodnocených testování sítě učené metodou LM z předchozího úkolu. Vidíme, že fáze bdění byla špatně klasifikována ve 134 případech z 560, přičemž nejčastěji byla nesprávně klasifikována jako fáze N3. Naopak fáze hlubokého spánku byla správně rozpoznána v 509 případech. Je zajímavé, že byla fáze W zaměněna s fází N3 ve 100 případech, i když se jedná o dvě nejrozdílnější fáze. Naznačuje to, že se charakteristické rysy těchto dvou fází u pacientů 010 a 007 liší a tudíž by bylo vhodné pro učení použít data od jiného nebo více pacientů.

Tabulka 5.1 Matice záměn jednoho testování neuronové sítě (metoda LM, fáze W, N3, REM, data od dvou pacientů)


		Skutečná hodnota		
		W	N3	REM
Očekávaná hodnota	W	426	100	34
	N3	46	509	5
	REM	12	64	484

V poslední části byly opět přidány pro klasifikaci fáze N1 a N2 a byl tak klasifikován celý spánek. Velikosti učební a testovací matice zůstaly zachovány z předchozí podkapitoly, pouze testovací data samozřejmě pochází od pacienta 007. Výsledky testování všech variant neuronových sítí vidíme na Obrázek 5.14. Vzhledem k tomu, že situaci, kdy učební data pochází od jediného pacienta a testování probíhá na pacientovi jiném, lze považovat za přístup, kdy budou dosaženy nejhorší výsledky, není výsledek testování natolik překvapivý. Ve většině případů bylo dosaženo nižší, než 50% úspěšnosti, u sítí učených metodou gradientního sestupu se dokonce jedná o méně než 40%.



Obrázek 5.14 Výsledky testování různých nastavení neuronových sítí (všechny fáze, pacienti 010 a 007)

Výsledky opakovaného učení a testování nejlepších nastavení sítí na Obrázek 5.15 potvrzují výše uvedené zjištění. Pokud tedy budeme chtít klasifikovat všech pět spánkových fází, není vhodné, abychom učili neuronovou síť na datech od pouze jednoho pacienta. I pro nejlepší možné nastavení neuronové sítě bylo dosaženo maximálně 50% správně klasifikovaných fází, v jednom případě dokonce dosáhla úspěšnost pouhých 20%. Tento postup tedy nelze považovat jako vhodný pro klasifikaci spánkových fází, dokonce ani jako pomůcku při manuálním skórování.



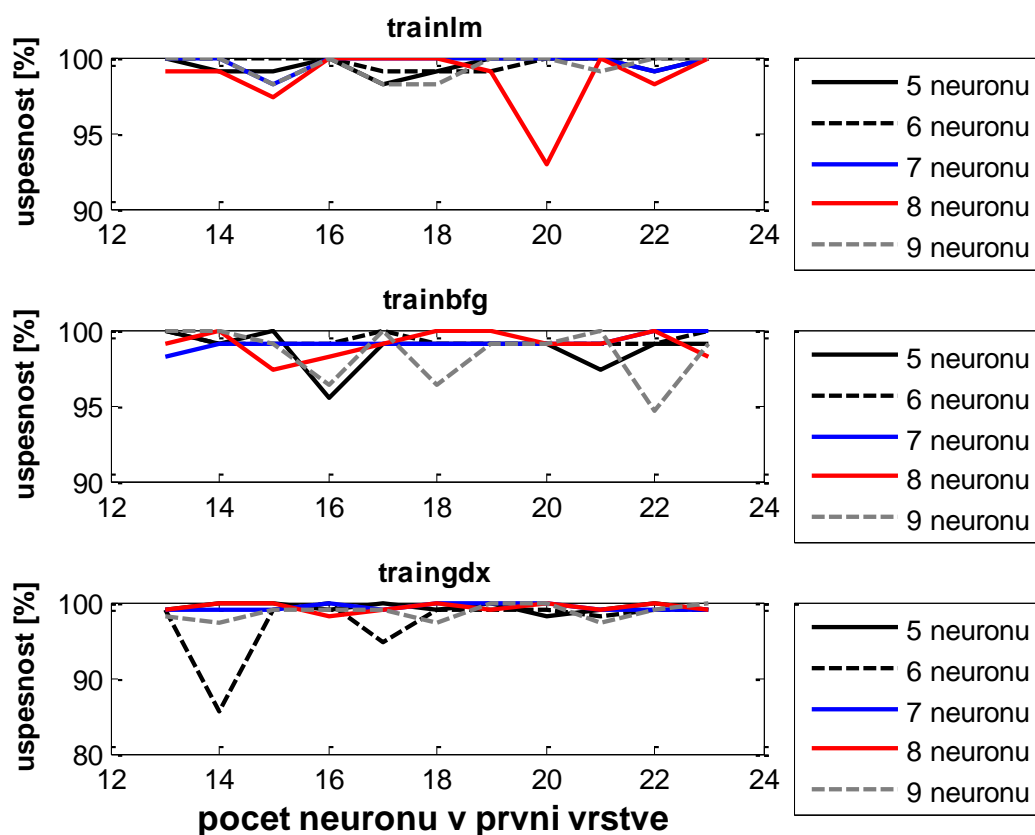
Obrázek 5.15 Výsledky opakovaného učení a testování nejlepšího nastavení neuronové sítě (všechny fáze, pacienti 010 a 007)

5.4. Data od třech pacientů

V předchozí podkapitole byl ukázán nejjednodušší způsob učení a testování neuronových sítí, který by byl teoreticky použitelný v klinické praxi. Z výsledků v předchozích podkapitolách lze usoudit, že učení neuronové sítě s pomocí dat od jednoho pacienta se hodí převážně pouze tehdy, pokud klasifikujeme data od stejného pacienta. Proto je mnohem vhodnější pro učení použít soubor dat, složený ze záznamů od více než jednoho pacient, nejjednodušším případem je stav, kdy učíme síť na datech od dvou různých pacientů, v našem případě jsou to pacienti 007 a 010, jako testovací posloužila data od pacienta 006. Učební množina pak byla vždy vytvářena tak, že pro každou klasifikovanou fázi bylo náhodně vybráno 280 vektorů s patnácti klasifikačními příznaky a následně byla výsledná učební matice složena z první poloviny dat od pacienta 007 a druhé poloviny dat pacienta 010. Vhodné je podotknout, že při použití opačného složení učebních dat bylo dosaženo ekvivalentních výsledků. Testovací data od pacienta 006 byla získána standardně náhodným výběrem 56 vektorů s parametry.


V první části byly standardně klasifikovány pouze fáze W a N3. Výsledky testování můžeme vidět na Obrázek 5.16. Podobně jako v předchozí podkapitole vidíme, že bylo dosaženo téměř 100% úspěšnosti klasifikace, občasné poklesy jsou způsobeny především tím, že jsou na začátku všechny hodnoty vah a prahů jednotlivých neuronů nastaveny náhodně, po

předložení učební množiny se pak může stát, že hodnota gradientu klesne natolik, že se síť po zbytek procesu není schopná dále naučit.



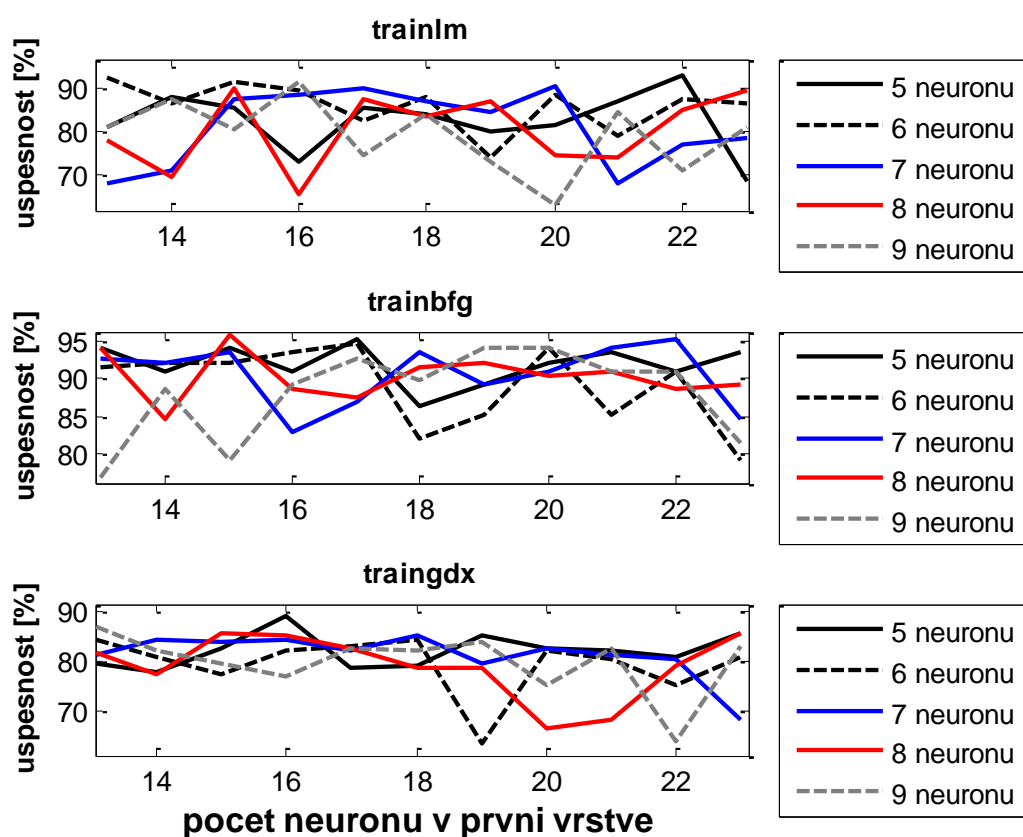
Obrázek 5.16 Výsledky testování různých nastavení neuronových sítí (fáze W a N3, pacienti 007, 010 a 006)

Abychom zabránili ovlivnění výsledků takovými náhodnými výkyvy, provedeme opět dvacet na sobě nezávislých procesů učení a testování pro nastavení sítě LM 16-6, BFG 18-8 a GDX 18-8. Na Obrázek 5.17 vidíme výsledné krabicové grafy tohoto testování. Pro klasifikaci se nejlépe hodí síť, učená metodou gradientního sestupu, neboť jejich výsledky vykazují nejmenší rozsah výsledných hodnot a kromě jednoho případu z dvaceti nebyla úspěšnost klasifikace horší, než 99%. Srovnáme-li výsledky s klasifikací dvou spánkových fází z předchozí podkapitoly na Obrázek 5.11, zjistíme, že bylo dosaženo přibližně o 5% vyšší úspěšnosti klasifikace, než pokud byly jako učební použity data od jednoho pacienta. Tento jev tak potvrzuje předpoklad z předchozí podkapitoly, tedy že zvýšením počtu jedinců použitých pro učení neuronové sítě lze zvýšit úspěšnost klasifikace.




Obrázek 5.17 Výsledky opakovaného učení a testování nejlepšího nastavení neuronové sítě (fáze W a N3, pacienti 007, 010 a 006)

V druhé části podkapitoly byla opět pro klasifikaci přidána fáze REM. Přestože se tím pravděpodobně zhorší úspěšnost klasifikace proti předchozímu případu se dvěma fázemi, lze rovněž očekávat, že bude dosaženo lepších výsledků, než v případě učebních dat od jednoho pacienta. Výsledky testování všech variant neuronových sítí vidíme na Obrázek 5.18. Z grafů můžeme pozorovat, že zkombinováním vstupních dat od více pacientů začíná klesat spolehlivost sítí, učených metodou LM a začíná být výhodnější použití složitějších algoritmů. Konkrétně u metody učení BFG se zdá, že dosahuje nejlepších výsledků bez velkých změn při různých nastaveních sítí. U metody GDX je nižších hodnot úspěšnosti klasifikace dosaženo především proto, že po 500 učeních sítě bylo dosaženo u hodnoty MSE obvykle 0,05 – 0,08, další učení již vzhledem k vývoji učebního procesu nemělo smysl.



Obrázek 5.18 Výsledky testování různých nastavení neuronových sítí (fáze W, N3 a REM, pacienti 007, 010 a 006)

Pokles spolehlivosti klasifikace metodou LM potvrzují i krabicové grafy na Obrázek 5.19. Zvýšený počet odlehlých hodnot úspěšnosti klasifikace s minimem pod 50% ukazuje, že mají neuronové sítě učené metodou LM problémy s daty od více pacientů a často tak dojde při učení k poklesu gradientu na takovou hodnotu, která znemožňuje další učení. V grafech se rovněž potvrzuje, že v tomto případě je pro učení neuronové sítě nejvhodnější metoda BFG, která vykazuje úspěšnost klasifikace přes 90%. Při srovnání s učením od jednoho pacienta zjistíme, že ačkoliv se úspěšnost klasifikace při učení metodou LM zhoršila, při použití metody učení BFG získáme zlepšení zhruba o 5%.



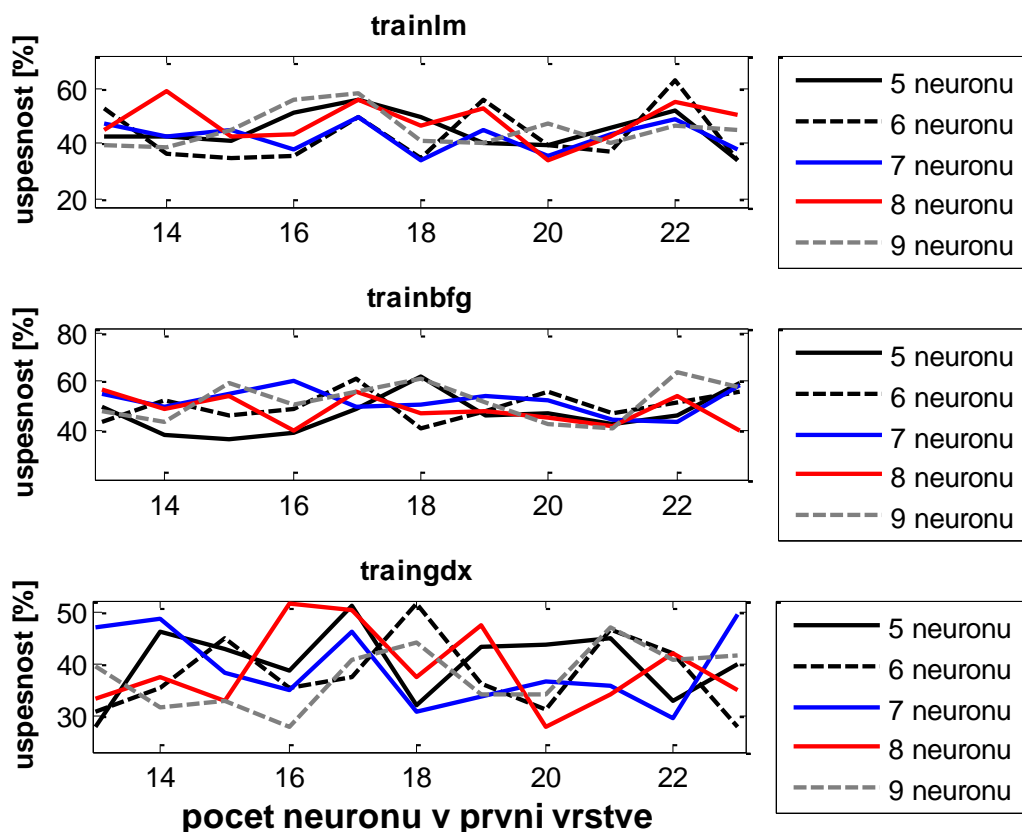
Obrázek 5.19 Výsledky opakovaného učení a testování nejlepšího nastavení neuronové sítě (fáze W, N3 a REM, pacienti 007, 010 a 006)

Při srovnávání je rovněž vhodné opět uvést i zjednodušenou matici záměn, které nám ukazuje, které fáze byly klasifikovány s jakou úspěšností. Tato tabulka byla opět vytvořena z deseti opakovaných učení a testování neuronových sítí z předchozího úkolu, použita byla metoda učení BFG. Můžeme si všimnout, že všech 560 testovaných fází W bylo klasifikováno správně. Proti tomu měl klasifikátor problém správně rozpoznat fázi N3, která byla v 78 případech (13,9%) označena za fázi REM. Fáze REM pak byla špatně klasifikována v 16,3% případů.

Tabulka 5.2 Matice záměn jednoho testování neuronové sítě (metoda BFG, fáze W, N3, REM, data od tří pacientů)


		Skutečná hodnota		
		W	N3	REM
Očekávaná hodnota	W	560	0	0
	N3	0	482	78
	REM	43	48	469

V poslední části podkapitoly byly opět klasifikovány všechny spánkové fáze. Proti předchozí kapitole, kdy byla dosažená úspěšnost naprosto nedostatečná, lze očekávat zlepšení, otázkou však zůstává, zda bude dosaženo takových hodnot, aby byl algoritmus použitelný pro spolehlivou klasifikaci. Výsledky testování všech používaných kombinací nastavení neuronové sítě vidíme na Obrázek 5.20. Můžeme si všimnout, že bylo skutečně dosaženo lepších výsledků než v případě učení sítě z dat od jednoho pacienta, nicméně dosažená úspěšnost se stále pohybuje v rozmezí 50-60%.



Obrázek 5.20 Výsledky testování různých nastavení neuronových sítí (všechny fáze, pacienti 007, 010 a 006)

Pro opakované učení a testování nejlepšího nastavení neuronové sítě byly vybrány následující konfigurace: LM 17-9, BFG 18-9 a GDX 16-8. Již podle předchozích výsledků se dalo očekávat, že nejnižší úspěšnosti klasifikace dosáhne metoda gradientního sestupu, což se potvrzuje na Obrázek 5.21. Z něj také vyčteme, že nejlepších výsledků dosáhla metoda BFG s mediánovou hodnotou zhruba 50% a nejvyšší dosaženou úspěšností 65%. Metoda LM již přestala být vhodná jak z hlediska úspěšnosti, tak i rychlosti učení sítě, neboť doba trvání 500 iterací odpovídala metodě BFG, nicméně při učení nebylo dosaženo hodnot MSE nižších, než 0,05.



Obrázek 5.21 Výsledky opakovaného učení a testování nejlepšího nastavení neuronové sítě (všechny fáze, pacienti 007, 010 a 006)

Vzhledem k tomu, že úspěšnost klasifikace přidáním dat od dalšího pacienta dosáhla zlepšení, je vhodné podívat se blíže na matici záměn, abychom zjistili, kde klasifikátor selhává. Z Tabulka 5.3 pozorujeme, že dříve klasifikované fáze W, N3 a REM dosahují stále úspěšnosti nad 80%. Problematické je tedy skórování fáze N1 a především N2, která byla ve většině případů klasifikována jako REM a pouze jednou z 56 případů byla určena správně. Fáze N2 je pro klasifikaci komplikovaná, především díky podobnosti se všemi ostatními fázemi, zde mohla klasifikátor zmást především přítomnost frekvencí EEG do 10Hz, které se vyskytují i ve fázi REM.

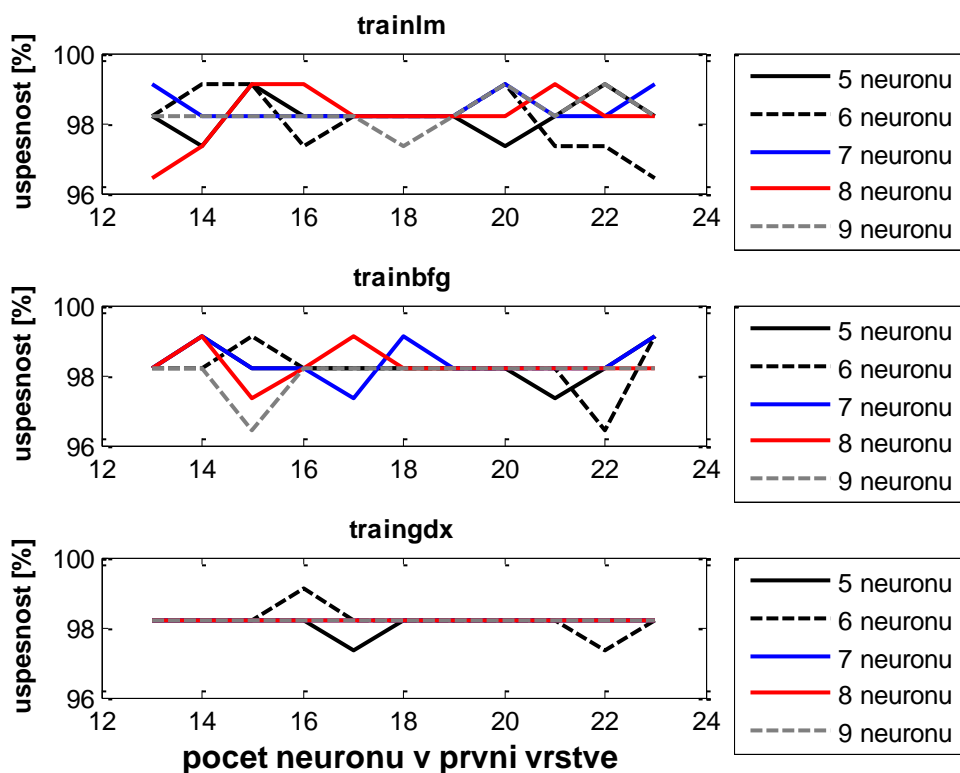
Tabulka 5.3 Matice záměn jednoho testování neuronové sítě (metoda BFG, všechny fáze, data od tří pacientů)

		Skutečná hodnota					Úspěšnost [%]
		W	N1	N2	N3	REM	
Očekávaná hodnota	W	46	10	0	0	0	82,14
	N1	1	35	19	1	0	62,50
	N2	1	0	1	8	46	1,79
	N3	0	0	0	55	1	98,21
	REM	3	4	1	3	45	80,35

5.5. Data od čtyř pacientů


V předchozí kapitole bylo prokázáno, že klasifikace spánkových fází pomocí neuronových sítí, naučených na datech pocházejících od dvou pacientů, je úspěšnější, než pokud k učení použijeme pouze data od jednoho pacienta. V této podkapitole pak bude otestováno, zdali a pokud ano tak jakou mírou se zlepší úspěšnost klasifikace, pokud pro učení použijeme data od třetího pacienta. Princip vytváření učební matice zůstává stejný, jako v předchozí kapitole, nejprve jsou vytvořeny tři učební matice z dat od jednotlivých pacientů (280 vektorů s 15 parametry pro každou klasifikovanou fázi) a následně je vytvořena výsledná matice pro učení z částí těchto tří matic. Pro učení jsou opět použita data od pacientů číslo 007 a 010, přidána jsou data od pacienta 008. Pro testování pak byla použita stejná data od pacienta 006, jako v předchozí podkapitole.

V poslední podkapitole věnované samotné klasifikaci spánkových fází byly nejprve klasifikovány fáze W a N3. Vzhledem k výborným výsledkům z předchozí podkapitoly lze očekávat, že v případě skórování bdění/hluboký spánek nedojde k dalšímu zlepšování výsledků. Následující Obrázek 5.22 potvrzuje tento předpoklad. Můžeme si však všimnout, že u posledního grafu, odpovídajícímu úspěšnosti klasifikace sítí učených pomocí metody GDX, byla úspěšnost klasifikace stejná ve 47 z 50 případů.



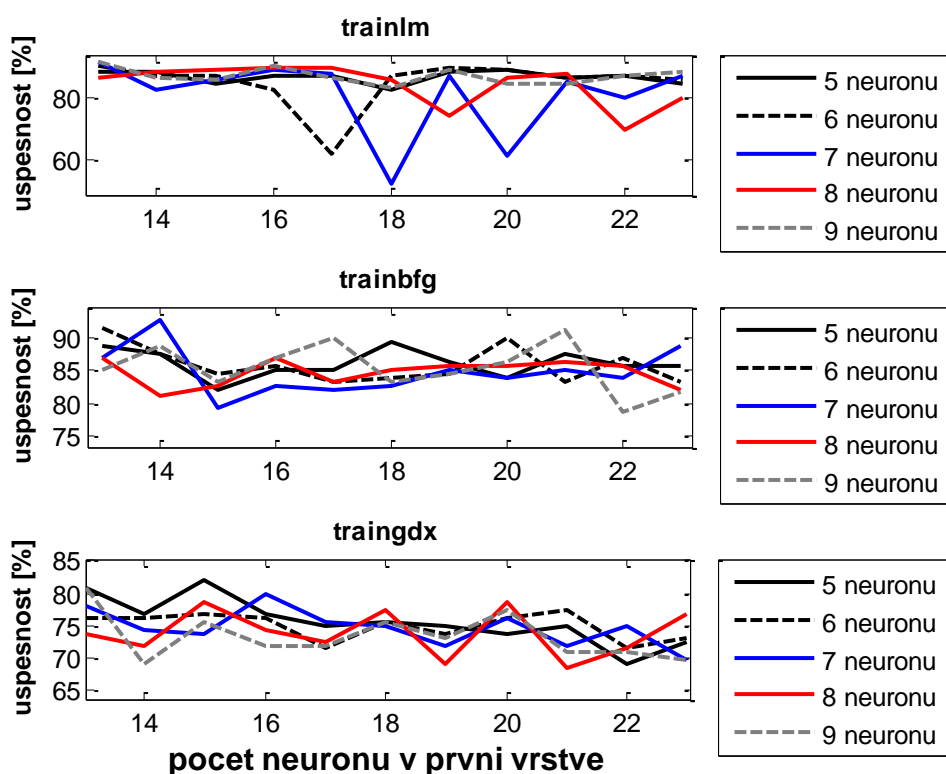
Obrázek 5.22 Výsledky testování různých nastavení neuronových sítí (fáze W a N3, pacienti 007, 008, 010 a 006)

Pro další učení a testování nejlepších nastavení sítí, byly zvoleny počty neuronů 16-8 pro učení metodou LM, 18-7 pro metodu BFG a 16-6 pro GDX. Výsledky tohoto procesu jsou znázorněny krabicovými grafy na Obrázek 5.23. Můžeme si všimnout, že ačkoliv úspěšnost klasifikace nikdy nedosahuje 100%, jsou hodnoty až na výjimky stabilní pro každé testování, i když bylo pokaždé provedeno nové učení sítě. Tvary grafů se tak více podobají situaci, kdy byly pro učení i testování použity data od stejného pacienta. Podobnost s touto situací nastává i v počtu špatně klasifikovaných fází. Ve všech 60 cyklech učení - testování bylo správně klasifikováno 100% fází N3, k chybám tedy docházelo pouze při klasifikaci fáze W.




Obrázek 5.23 Výsledky opakovaného učení a testování nejlepšího nastavení neuronové sítě (fáze W a N3, pacienti 007, 008, 010 a 006)

Zdali přidání učebních dat od dalšího pacienta přineslo znatelné zlepšení úspěšnosti klasifikace, by měla ukázat situace, kdy je ke klasifikovaným fázím přidána fáze REM. Po naučení a otestování neuronových sítí pro všechny kombinace možného nastavení a následném vytvoření grafů na Obrázek 5.24 lze usuzovat, že ačkoliv pravděpodobně k velkému zlepšení nedošlo, nastalo podobně jako v předchozím případě snížení odchylek u jednotlivých výsledků. Jako nejvhodnější se zde, podobně jako v předchozí podkapitole, jeví neuronové sítě, učené pomocí metody BFG.



Obrázek 5.24 Výsledky testování různých nastavení neuronových sítí (fáze W, N3 a REM, pacienti 007, 008, 010 a 006)

Pro opakované učení a testování byly za pomoci grafů na předchozím obrázku vybrány konfigurace neuronových sítí 17-8, 14-7 a 15-5 pro metody LM, BFG respektive GDX. Výsledné krabicové grafy na Obrázek 5.25 přináší poněkud překvapivé zjištění. Výsledné hodnoty úspěšnosti klasifikace byly pro metodu BFG nižší, než v případě z předchozí podkapitoly a ačkoliv při učení dvěma pacienty bylo dosaženo úspěšnosti přes 90%, v tomto případě se hodnoty pohybují kolem 85%. Naopak lepších výsledků bylo dosaženo při použití metody LM, a ačkoliv docházelo k větším výkyvům hodnot, lze úspěšnost klasifikace nad 85% považovat za dostatečnou, vzhledem k rychlosti učení této metody. Podobně jako v předchozí podkapitole i zde dopadla metoda GDX nejhůře a pro klasifikaci ji v tomto případě nelze doporučit.



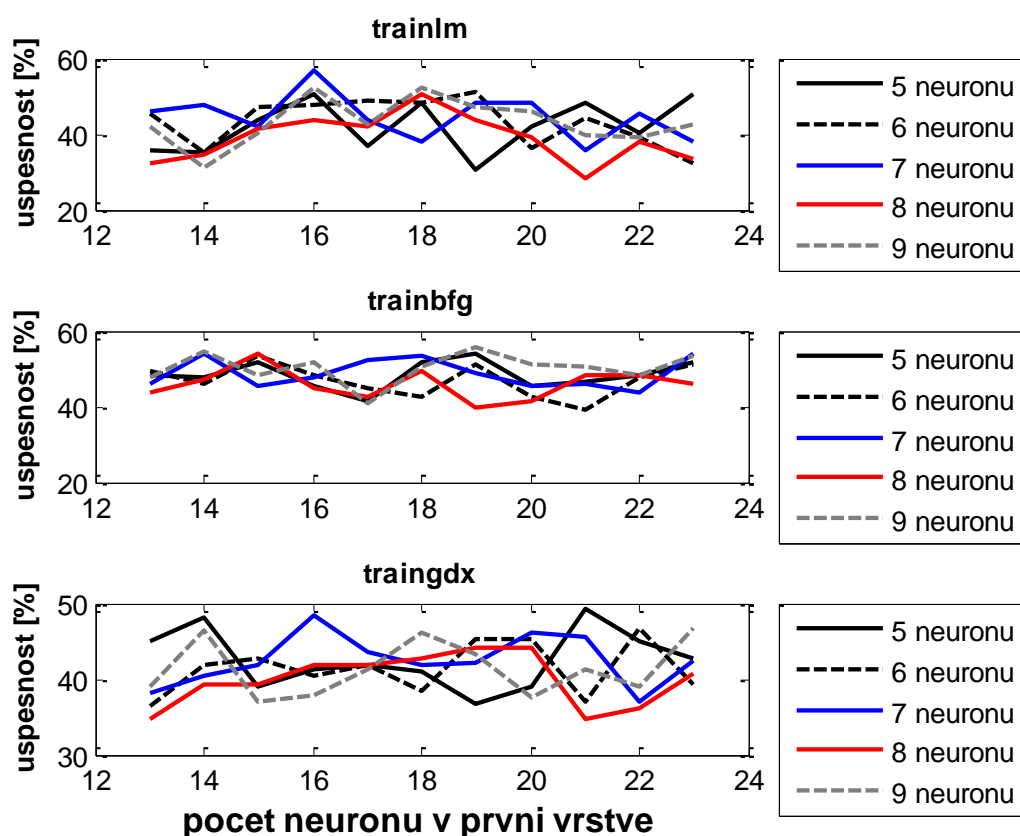
Obrázek 5.25 Výsledky opakovaného učení a testování nejlepšího nastavení neuronové sítě (fáze W, N3 a REM, pacienti 007, 008, 010 a 006)

Bližší pohled na výsledky klasifikace poskytuje zjednodušená matice záměn v Tabulka 5.4. Při porovnání s Tabulka 5.2 z předchozí podkapitoly zjistíme, že se přidáním dalšího pacienta do procesu učení neuronové sítě sice zvýšila úspěšnost klasifikace fáze N3, zhoršila se naopak schopnost sítě rozpoznat fázi REM. U této fáze byla dosažena úspěšnost klasifikace pouhých 61%, chyby se objevily i u fáze W a v jednom případě byla špatně klasifikována fáze N3.

Tabulka 5.4 Matice záměn jednoho testování neuronové sítě (metoda BFG, fáze W, N3, REM, data od čtyř pacientů)


		Skutečná hodnota		
		W	N3	REM
Očekávaná hodnota	W	527	15	18
	N3	0	559	1
	REM	51	166	343

V poslední klasifikaci této práce byly zahrnuty všechny spánkové fáze. Již v předchozí části bylo naznačeno vyvrácení předpokladu, že s vyšším počtem pacientů pro učení se úspěšnost klasifikace zvýší. Již během učení sítí si šlo všimnout, že se rychlost učení zpomalila kolem hodnot MSE 0,2-0,3 a dále se již tato hodnota zlepšovala jen velmi pomalu s cílovou hodnotou vždy přesahující 0,05. Výsledky testování všech nastavení neuronových sítí reprezentuje Obrázek 5.26. Ten je podobný situaci v předchozí podkapitole, kdy se úspěšnost rovněž pohybovala kolem 50%. Jako nejlepší metoda učení se zde opět jeví metoda BFG, povšimnout si však můžeme zlepšení úspěšností sítí učených gradientním sestupem.



Obrázek 5.26 Výsledky testování různých nastavení neuronových sítí (všechny fáze, pacienti 007, 008, 010 a 006)

Z dosažených výsledků byly vybrány nejlepší nastavení neuronových sítí, pro učební metodu LM 16-7, pro metodu BFG 19-9 a pro GDX 21-5. Výsledky opakovaného učení a testování vidíme na Obrázek 5.27. Výsledné krabicové grafy jenom potvrzují zjištění z testování různých nastavení, tedy že přidáním učebních dat od dalšího pacienta se úspěšnost klasifikace nezlepší. Proti Obrázek 5.21 z předchozí podkapitoly dokonce pozorujeme zhoršení o 5% pro metodu BFG, která se stále jeví jako nejlepší varianta pro učení neuronové sítě.



Obrázek 5.27 Výsledky opakovaného učení a testování nejlepšího nastavení neuronové sítě (všechny fáze, pacienti 007, 008, 010 a 006)

I v tomto případě se podíváme na jednu matici záměn v Tabulka 5.5, jedná se o testování sítě učené metodou BFG, vybráno bylo nejúspěšnější testování s celkovou úspěšností 55%. V tabulce si můžeme všimnout, že fáze W a N3 opět nečinily klasifikátoru větší potíže. Problematické je však opět rozlišení fází N2 a REM, které výrazně snižuje celkovou úspěšnost klasifikace. Rovněž fáze N1 je často zaměňována za fáze W a N2. Tato záměna je z fyziologického hlediska pochopitelná, neboť jak již bylo zmíněno, jedná se o jakousi přechodovou fázi. Řešením těchto záměn by mohlo být přidání dalších klasifikačních příznaků, nabízí se například detekce K-komplexů nebo spánkových vřeten

Tabulka 5.5 Matice záměn jednoho testování neuronové sítě (metoda BFG, všechny fáze, data od čtyř pacientů)

		Skutečná hodnota					Úspěšnost [%]
		W	N1	N2	N3	REM	
Očekávaná hodnota	W	48	5	1	1	1	85,71
	N1	14	22	16	1	3	39,29
	N2	1	0	18	13	23	32,14
	N3	0	0	3	53	0	94,64
	REM	6	5	23	8	13	23,21

5.6. Shrnutí a porovnání výsledků

Ve čtyřech předchozích podkapitolách byla pomocí neuronových sítí klasifikována PSG data, provedeno bylo testování pro různý původ učebních a testovacích dat, dále pro různý počet klasifikovaných fází, pro různé metody učení neuronové sítě a pro více možností nastavení počtu neuronů ve skrytých vrstvách neuronové sítě. Přehled dosažených výsledků poskytuje Tabulka 5.6. Procentuální hodnoty byly odečteny z krabicových grafů a odpovídají interkvartilovým hodnotám.

Tabulka 5.6 Srovnání výsledků dosažených při klasifikaci spánkových fází

číslo pacienta			úspěšnost [%]		
učební data	testovací data	Klasifikované fáze	LM	BFG	GDX
010	010	W, N3	100	100	97-100
		W, N3, R	99-100	97-99	92-95
		W, N1-3, R	69-73	72-76	55-60
010	007	W, N3	90-94	87-92	88-93
		W, N3, R	85-88	82-85	75-80
		W, N1-3, R	35-43	40-48	30-40
007, 010	006	W, N3	98-100	98,5-99	99-99,5
		W, N3, R	80-85	89-94	80-85
		W, N1-3, R	40-51	43-56	33-36
007, 008, 010	006	W, N3	98,3	98,3-99	98,3
		W, N3, R	86-90	83-86	73-75
		W, N1-3, R	38-46	43-50	40-45

Srovnáme-li výsledky z pohledu počtu pacientů použitých pro učení a testování sítí, dosahujeme nejvyšší úspěšnosti u případu, kdy jsou pro učení i testování použita data od jednoho pacienta. Jak již ale bylo řečeno, takový přístup z hlediska nasazení do klinické praxe není příliš vhodný, a proto ho nebudeme uvažovat. Nejlepších výsledků bylo tedy dosaženo v případě, že jsme pro učení použili data od dvou pacientů a testovali na datech od pacienta třetího.

Při porovnání výsledků pro různý počet klasifikovaných fází je pochopitelné, že nejlepší klasifikace je dosaženo tehdy, rozlišujeme-li pouze bdění a hluboký spánek. Zde bylo dosaženo téměř 100% úspěšnosti a pro klasifikaci těchto dvou fází by bylo možné síť použít. Rovněž při přidání klasifikace fáze REM bylo dosaženo výsledků přesahujících 80%, v některých případech až 94%. Takové výsledky lze rovněž považovat za uspokojivé, neboť jak bylo zmíněno dříve, shoda dvou expertů běžně dosahuje zhruba 82%. Naopak pro klasifikaci fází N1 a N2 se uvedený postup nehodí.

Poslední se nabízí srovnání metod učení neuronových sítí. Zde dosahujeme různých výsledků, obecně lze ale říct, že metoda GDX se pro klasifikaci PSG dat nehodí. Při porovnání zbylých dvou metod zjišťujeme, že metoda LM je vhodnější při zpracování menšího množství dat a při klasifikaci méně fází, její výhodou je v těchto případech i rychlost algoritmu. Proti tomu síť učené metodou BFG je vhodnější použít pro případy, kdy klasifikujeme větší množství spánkových fází nebo používáme data od více pacientů.

Pro zhodnocení výsledků práce je také vhodné srovnání s jinými pracemi. Přehled dosažených výsledků v použité literatuře poskytuje již dříve uváděná Tabulka 3.1. Podle ní si můžeme udělat přehled, jakých výsledků lze dosáhnout při klasifikaci PSG dat za pomoci různých klasifikačních příznaků a metod. Podíváme-li se na úspěšnosti publikovaných metod, můžeme říci, že úspěšnost přes 80% při klasifikaci fází W, N3 a REM v této práci odpovídá běžně dosahovaným výsledkům. Naopak při klasifikaci všech spánkových fází bylo dosaženo výsledků podprůměrných.

6. Závěr

Úkolem diplomové práce bylo seznámení se s metodami pro klasifikaci spánkových fází na základě PSG záznamů pacientů. Toto seznámení je provedeno v prvních třech kapitolách formou rešerše, zabývající se problematikou polysomnografie a klasifikace spánkových fází. Rovněž je věnován prostor metodám pro získání klasifikačních příznaků ze signálů a některým použitelným klasifikačním metodám.

Při práci s reálnými PSG daty z Fakultní nemocnice u svaté Anny v Brně byly použity poznatky z předchozích kapitol pro časovou, frekvenční a časově-frekvenční analýzu signálů EEG, EOG a EMG, výsledky byly následně statisticky hodnoceny a byla posouzena vhodnost parametrů pro automatickou klasifikaci spánkových fází. V kapitole bylo poukázáno na nedostatečné časové rozlišení konvenčních skórovacích postupů, a proto byla následná klasifikace prováděna se sekundovým rozlišením.

Samotné klasifikaci pomocí neuronových sítí pak byla věnována pátá kapitola, ve které byly vysvětleny parametry, použité při nastavení neuronových sítí a ve které je klasifikace PSG dat rozdělena na čtyři podkapitoly, v závislosti na původu použitých učebních a testovacích dat. V každé podkapitole pak byly testovány různé nastavení neuronových sítí a úspěšnost klasifikace dvou, tří nebo pěti spánkových fází. Všechny výsledky pak byly prezentovány pomocí grafů, krabicových grafů a případně matic záměn.

V poslední podkapitole bylo provedeno zhodnocení dosažených výsledků podle různých kritérií. Srovnání bylo provedeno také s již existujícími studiemi, jejichž přehled byl prezentován formou tabulky. Celková úspěšnost klasifikace pak byla hodnocena jako úspěšná pro klasifikaci dvou a tří spánkových fází, u pěti klasifikovaných fází byly odhaleny nedostatky použitých parametrů, které s nejvyšší pravděpodobností zapříčiňují nízkou úspěšnost klasifikace. Nutno nicméně myslet na to, že klasifikace spánkových fází v této práci byla prováděna s třicetinásobným časovým rozlišením, než je běžné, což také úspěšnost klasifikace snižuje. Přidáním dalších parametrů nebo použitím dalších signálů by se tak tato metoda klasifikace PSG dat mohla stát použitelnou i v praxi. Dílčí výsledky klasifikace byly rovněž prezentovány na konferenci Student EEICT 2015 [12].

Seznam použitých zkratek

AASM	Americká akademie spánkové medicíny
BFG	BFGS quasi-Newtonova metoda
DFT	Diskrétní Fourierova transformace
EEG	Elektroencefalogram
EKG	Elektrokardiogram
EMG	Elektromyogram
EOG	Elektrookulogram
ES	Expertní systém
FFT	Rychlá Fourierova transformace
FT	Fourierova transformace
GDX	Metoda gradientního sestupu
LM	Metoda Levenberg-Marquardt
N1	Fáze Non-REM 1
N2	Fáze Non-REM 2
N3	Fáze Non-REM 3
PSD	Výkonová spektrální hustota
PSG	Polysomnografie
R	Fáze REM
RMS	Kvadratický průměr
STFT	Krátkodobá Fourierova transformace
W	Fáze Wake

Seznam obrázků

Obrázek 2.1 Doporučené (A) a alternativní (B) svody EEG, dle doporučení AASM [17]...	- 4 -
Obrázek 2.2 Ukázka spánkových vřeten (nahore) a K-komplexu (dole) [17]	- 5 -
Obrázek 2.3 Umístění elektrod pro měření EMGsub [3]	- 6 -
Obrázek 2.4 Možné rozmístění elektrod při měření EOG [17].....	- 6 -
Obrázek 2.5 Ukázka fáze W.....	- 8 -
Obrázek 2.6 Ukázka fáze N1.....	- 8 -
Obrázek 2.7 Ukázka fáze N2.....	- 9 -
Obrázek 2.8 Ukázka fáze N3.....	- 10 -
Obrázek 2.9 Ukázka fáze REM.....	- 10 -
Obrázek 3.1 Ukázka PSD s jedné epochy PSD vyznačením frekvenčních pásem	- 13 -
Obrázek 3.2 Diskrétní CWT akustického signálu (převzato a upraveno [6])	- 15 -
Obrázek 3.3 Koncept expertního systému [skripta AUIN]	- 16 -
Obrázek 3.4 Schéma neuronu [9]	- 17 -
Obrázek 4.1 Rozmístění elektrod pro snímání EEG v rámci studie RELIEF [3]	- 20 -
Obrázek 4.2 Ukázky signálů (fáze N2)	- 21 -
Obrázek 4.3 Průměrné hodnoty signálu EEG	- 22 -
Obrázek 4.4 Průměrné hodnoty signálu EOG	- 23 -
Obrázek 4.5 Průměrné hodnoty signálu EMG	- 23 -
Obrázek 4.6 Směrodatné odchylky signálu EEG	- 24 -
Obrázek 4.7 Směrodatné odchylky signálu EOG.....	- 25 -
Obrázek 4.8 Směrodatné odchylky signálu EMG	- 25 -
Obrázek 4.9 Rozptyl signálu EEG	- 26 -
Obrázek 4.10 Rozptyl signálu EOG	- 26 -
Obrázek 4.11 Rozptyl signálu EMG	- 27 -
Obrázek 4.12 Porovnání PSD fází W a N3	- 28 -
Obrázek 4.13 Zastoupení delta a theta rytmu ve spektru	- 29 -
Obrázek 4.14 Zastoupení alfa a beta rytmu ve spektru	- 30 -
Obrázek 4.15 Ukázka spektrogramu (fáze W)	- 31 -
Obrázek 4.16 Srovnání dvou spektrogramů	- 32 -
Obrázek 4.17 Dva spektrogramy s přechody mezi fázemi.....	- 32 -
Obrázek 5.1 Ukázka původního signálu EOG (a), EMG (b) a vypočtených parametrů pro EOG (c) a EMG (d)	- 34 -
Obrázek 5.2 Ukázka parametrů pro EEG.....	- 35 -
Obrázek 5.3 Schéma použité neuronové sítě.....	- 35 -
Obrázek 5.4 Výsledky testování různých nastavení neuronových sítí (fáze W a N3, pacient 010)	- 37 -

Obrázek 5.5 Výsledky opakovaného učení a testování nejlepšího nastavení neuronové sítě (fáze W a N3, pacient 010).....	- 38 -
Obrázek 5.6 Výsledky testování různých nastavení neuronových sítí (fáze W, N3, R, pacient 010).....	- 39 -
Obrázek 5.7 Výsledky opakovaného učení a testování nejlepšího nastavení neuronové sítě (fáze W, N3 a R, pacient 010).....	- 40 -
Obrázek 5.8 Výsledky testování různých nastavení neuronových sítí (všechny fáze, pacient 010).....	- 41 -
Obrázek 5.9 Výsledky opakovaného učení a testování nejlepšího nastavení neuronové sítě (všechny fáze, pacient 010).....	- 42 -
Obrázek 5.10 Výsledky testování různých nastavení neuronových sítí (fáze W a N3, pacienti 010 a 007).....	- 43 -
Obrázek 5.11 Výsledky opakovaného učení a testování nejlepšího nastavení neuronové sítě (fáze W a N3, pacienti 010 a 007).....	- 44 -
Obrázek 5.12 Výsledky testování různých nastavení neuronových sítí (fáze W, N3, REM, pacienti 010 a 007).....	- 45 -
Obrázek 5.13 Výsledky opakovaného učení a testování nejlepšího nastavení neuronové sítě (fáze W, N3, REM, pacienti 010 a 007).....	- 46 -
Obrázek 5.14 Výsledky testování různých nastavení neuronových sítí (všechny fáze, pacienti 010 a 007).....	- 47 -
Obrázek 5.15 Výsledky opakovaného učení a testování nejlepšího nastavení neuronové sítě (všechny fáze, pacienti 010 a 007).....	- 48 -
Obrázek 5.16 Výsledky testování různých nastavení neuronových sítí (fáze W a N3, pacienti 007, 010 a 006).....	- 49 -
Obrázek 5.17 Výsledky opakovaného učení a testování nejlepšího nastavení neuronové sítě (fáze W a N3, pacienti 007, 010 a 006).....	- 50 -
Obrázek 5.18 Výsledky testování různých nastavení neuronových sítí (fáze W, N3 a REM, pacienti 007, 010 a 006).....	- 51 -
Obrázek 5.19 Výsledky opakovaného učení a testování nejlepšího nastavení neuronové sítě (fáze W, N3 a REM, pacienti 007, 010 a 006).....	- 52 -
Obrázek 5.20 Výsledky testování různých nastavení neuronových sítí (všechny fáze, pacienti 007, 010 a 006).....	- 53 -
Obrázek 5.21 Výsledky opakovaného učení a testování nejlepšího nastavení neuronové sítě (všechny fáze, pacienti 007, 010 a 006).....	- 54 -
Obrázek 5.22 Výsledky testování různých nastavení neuronových sítí (fáze W a N3, pacienti 007, 008, 010 a 006).....	- 55 -
Obrázek 5.23 Výsledky opakovaného učení a testování nejlepšího nastavení neuronové sítě (fáze W a N3, pacienti 007, 008, 010 a 006).....	- 56 -

Obrázek 5.24 Výsledky testování různých nastavení neuronových sítí (fáze W, N3 a REM, pacienti 007, 008, 010 a 006)	- 57 -
Obrázek 5.25 Výsledky opakovaného učení a testování nejlepšího nastavení neuronové sítě (fáze W, N3 a REM, pacienti 007, 008, 010 a 006)	- 58 -
Obrázek 5.26 Výsledky testování různých nastavení neuronových sítí (všechny fáze, pacienti 007, 008, 010 a 006)	- 59 -
Obrázek 5.27 Výsledky opakovaného učení a testování nejlepšího nastavení neuronové sítě (všechny fáze, pacienti 007, 008, 010 a 006)	- 60 -

Seznam tabulek

Tabulka 2.1 Frekvenční rozdělení vln v EEG	- 4 -
Tabulka 3.1 Srovnání různých metod klasifikace spánkových fází z literatury.....	- 18 -
Tabulka 4.1 Úryvek ze seznamu kanálů, měřených během studie RELIEF (převzato a upraveno [3]).....	- 19 -
Tabulka 5.1 Matice záměn jednoho testování neuronové sítě (metoda LM, fáze W, N3, REM, data od dvou pacientů)	- 46 -
Tabulka 5.2 Matice záměn jednoho testování neuronové sítě (metoda BFG, fáze W, N3, REM, data od tří pacientů).....	- 52 -
Tabulka 5.3 Matice záměn jednoho testování neuronové sítě (metoda BFG, všechny fáze, data od tří pacientů)	- 54 -
Tabulka 5.4 Matice záměn jednoho testování neuronové sítě (metoda BFG, fáze W, N3, REM, data od čtyř pacientů)	- 58 -
Tabulka 5.5 Matice záměn jednoho testování neuronové sítě (metoda BFG, všechny fáze, data od čtyř pacientů).....	- 60 -
Tabulka 5.6 Srovnání výsledků dosažených při klasifikaci spánkových fází	- 61 -

Seznam použité literatury

- [1] ÁLVAREZ-ESTÉVEZ, D., José M. FERNÁNDEZ-PASTORIZA, Elena HERNÁNDEZ-PEREIRA a Vicente MORET-BONILLO. A method for the automatic analysis of the sleep macrostructure in continuum. *Expert Systems with Applications* [online]. 2013, vol. 40, issue 5, s. 1796-1803 [cit. 2015-05-19]. DOI: 10.1016/j.eswa.2012.09.022
- [2] EBRAHIMI, F.; MIKAEILI, Edson ESTRADA a Homer NAZERAN. Automatic sleep stage classification based on EEG signals by using neural networks and wavelet packet coefficients. *2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. IEEE, 2008, s. 1151-1154. DOI: 10.1109/IEMBS.2008.4649365. Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4649365>
- [3] FAKULTNÍ NEMOCNICE U SV. ANNY. *Měření polysomnografických (PSG) signálů v rámci grantu „Význam spánkové apnoe v patofyziologii a léčbě fibrilace síní“: Manuál k měření* [.doc]. 23 s. [cit. 2015-05-19]. NS 100 98-4.
- [4] FRAIWAN, L, Khaldon LWEESY, Natheer KHASAWNEH, Heinrich WENZ a Hartmut DICKHAUS. Automated sleep stage identification system based on time–frequency analysis of a single EEG channel and random forest classifier. *Computer Methods and Programs in Biomedicine* [online]. 2012, vol. 108, issue 1, s. 10-19 [cit. 2015-05-19]. DOI: 10.1016/j.cmpb.2011.11.005.
- [5] IBER, C. *The AASM manual for the scoring of sleep and associated events: rules, terminology and technical specifications*. Westchester, IL: American Academy of Sleep Medicine, c2007, 59 p.
- [6] JAN, J. *Číslíková filtrace, analýza a restaurace signálů*. 2. upr. a rozš. vyd. Brno: VUTUM, 2002, 427 s. ISBN 80-214-2911-9
- [7] KEMP, B. *European Data Format* [online]. [cit. 2015-05-19]. Dostupné z: <http://www.edfplus.info/>

- [8] KOLÁŘ, R.: *Lékařská diagnostická technika*, skripta předmětu Lékařská diagnostická technika. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2007. ISBN: ABM 07-91
- [9] KOZUMPLÍK, J.; PROVAZNÍK. *Umělá inteligence v medicíně* [online]. Brno, 2007 [cit. 2015-05-19]. Dostupné z: <https://www.vutbr.cz/elearning/mod/resource/view.php?id=277841>
- [10] KOZUMPLÍK, J. *Umělá inteligence v medicíně AUIN (1), Umělé neuronové sítě* [online prezentace]. 2014 [cit. 2015-05-19]. Dostupné z https://www.vutbr.cz/elearning/file.php/148627/prednasky2014/AUIN_01_UNs-1.pdf
- [11] KOZUMPLÍK, J. *Umělá inteligence v medicíně AUIN (3), Shluková analýza* [online prezentace]. 2014 [cit. 2015-05-19]. Dostupné z https://www.vutbr.cz/elearning/file.php/148627/prednasky2014/AUIN_03_shlukova_a_nalyza-1.pdf
- [12] KRÁLÍK M.; Ronzhina M. PSG-Based classification of sleep phases. In *Proceedings of the 21st Conference Student EEICT 2015*. 2015. s.215-217 ISBN 978-80-214-214-5148-3
- [13] Matematika.cz. *Kategorie: Statistika* [online]. Nová média, s.r.o., 2006-2014 [cit. 2015-05-19]. Dostupné z: <http://www.matematika.cz/kategorie-statistika>
- [14] OROPESA E, Cycon HL, Jobert M. Sleep stage classification using Wavelet transform and neural network. ISCI Technical Report TR-99e008; 1999.
- [15] RONZHINA, M.; Janoušek, Kolářová, Nováková, Honzík a Provazník. Sleep scoring using artificial neural networks. *Sleep Medicine Reviews* [online]. 2012, vol. 16, issue 3, s. 251-263 [cit. 2015-05-19]. DOI: 10.1016/j.smrv.2011.06.003. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S1087079211000700>
- [16] ŠUŠMÁKOVÁ, K.: *Human sleep and sleep EEG. In Measurement Science Review*, 2004, roč. 4, č 2, s. 59-74. ISSN 1335-8871.

- [17] VAUGHN, B. V. Technical Review of Polysomnography. *CHEST Journal* [online]. 2008-12-01, vol. 134, issue 6, s. 1310- [cit. 2015-05-19]. DOI: 10.1378/chest.08-0812. Dostupné z: <http://journal.publications.chestnet.org/article.aspx?doi=10.1378/chest.08-0812>

Přílohy

Příloha A – Tabulka použitých signálů při studii RELIEF

Zkratka kanálu	Popis kanálu	Vzorkovací frekvence Hz	Poznámky k snímání
Abdo	Břišní pás snímající úsilí břicha	32	princip indukční pletysmografie
Airflow	Oronazální termočlánek	32	teplotně snímá proud vdechovaného a vydechovaného vzduchu důležité pro scoring apneí
C3M2	EEG kanál C3-M2	256	
C4M1	EEG kanál C4-M1	256	
Chin1Chin2	EMG brady	256	submentální
CzOz	EEG kanál Cz-Oz	256	
E1	Okulogram levého oka	256	Vztaženo vůči ref. Elektrode Fpz
E2	Okulogram pravého oka	256	Vztaženo vůči ref. Elektrode Fpz
FzCz	EEG kanál Fz-Cz	256	-
LALL	EKG kanál (III. svod proximální) LA=Left Arm LL=Left Leg	512	-
LLeg1LLeg2	EMG levé nohy	256	-
Position	Poziční senzor (pravý bok levý bok záda břicho)	16	-
RALA	EKG kanál (I. Svod proximální) RA=Right Arm LA=Left Arm	512	-
RALL	EKG kanál (II. Svod proximální) RA=Right Arm LL=Left Leg	512	-
RLeg1RLeg2	EMG pravé nohy	256	
Snore	Snímač chrápaní	256	Mikrofon
SpO2	Senzor saturace kyslíku v krvi (oxymetr)	16	
Sum	Sumační kanál Abdo+Thor	32	součet amplitud břišního a hrudního pásu důležité pro scoring respiračních událostí zejména tzv. respirační paradox
Thor	Hrudní pás snímající úsilí břicha	32	princip indukční pletysmografie - RIP
pNasal	Tlaková nazální kanyla	32	